

Classificação de risco de demência através da análise da marcha de pessoas idosas usando algoritmos de machine learning

Rai Braz Costa

Dissertação apresentada à Escola Superior de Educação do Instituto Politécnico de Bragança para obtenção do grau de Mestre em Exercício e Saúde.

Orientado por
António Miguel de Barros Monteiro
Tiago Manuel Cabral dos Santos Barbosa

Dezembro
2024

Classificação de risco de demência através da análise da marcha de pessoas idosas usando algoritmos de machine learning

Raí Braz Costa

*Dissertação apresentada à Escola Superior de Educação do Instituto Politécnico de
Bragança para a obtenção do grau de Mestre em Exercício e Saúde, ao abrigo do artigo
20º do Decreto-Lei 74/2006, de 24 de março.*

Orientado por
António Miguel de Barros Monteiro
Tiago Manuel Cabral dos Santos Barbosa

**Dezembro
2024**

RESUMO

O declínio irreversivelmente progressivo das funções fisiológicas é conhecido como envelhecimento. Entre essas alterações está o envelhecimento cerebral, que leva ao declínio cognitivo e à promoção da expressão da demência. Isso afeta diretamente a memória, a aprendizagem e as habilidades motoras, o que resulta em uma diminuição na eficiência da marcha. O objetivo foi investigar a viabilidade de identificar e classificar o risco de Demência com base na análise das variáveis cinemáticas relacionadas com a marcha de idosos, utilizando algoritmos de *machine learning*. Este estudo observacional transversal examinou uma amostra de 59 indivíduos com idades entre 60 ± 8 anos. Foram divididos em um grupo de idosos institucionalizados (GI) com 26 participantes e outro grupo não institucionalizado (GNI) com 33 participantes, todos residentes na cidade de Bragança. Os dados de marcha foram avaliados através de uma caminhada de 10 metros, capturados em vídeo e posteriormente analisados pelo software Kinovea. O estado cognitivo foi avaliado por meio do questionário Mini Exame do Estado Mental (MEEM). Para a análise estatística, o programa *PythonTM* foi utilizado para criar um modelo de algoritmos de *machine learning* para classificar o risco de demência associado aos idosos de acordo com suas variáveis de marcha. Os resultados deste estudo mostraram que os modelos algorítmicos alcançaram um desempenho global de 74,6%, com o algoritmo *Ada Boost* a liderar com 83,5%. A validação cruzada dos algoritmos revelou uma precisão global de 72%, com o Classificador de Vetores de Suporte a apresentar o melhor desempenho individual 80%, indicando que este modelo respondeu corretamente a 80% das classificações nos diferentes subconjuntos de dados. Portanto, concluímos que a avaliação da marcha, combinada com algoritmos de *machine learning*, evidenciou a relação entre as variáveis da marcha e a demência, tornando-se uma técnica segura e eficiente para a classificação da demência.

ABSTRACT

The irreversibly progressive decline in physiological functions is known as aging. Among these changes is brain aging, which leads to cognitive decline and the promotion of dementia expression. This directly affects memory, learning, and motor skills, which results in a decrease in gait efficiency. The aim was to investigate the feasibility of identifying and classifying the risk of dementia based on the analysis of kinematic variables related to gait in the elderly, using machine learning algorithms. This cross-sectional observational study examined a sample of 59 individuals aged 60 ± 8 years. They were divided into a group of institutionalized elderly (GI) with 26 participants and another non-institutionalized group (GNI) with 33 participants, all living in the city of Bragança. Gait data were collected through a 10-meter walk, captured on video and later analyzed by the Kinovea software. Cognitive status was assessed using the Mini Mental State Examination (MMSE) questionnaire. For the statistical analysis, the Python™ program was used to create a model of machine learning algorithms to classify the risk of dementia associated with the elderly according to their gait variables. The results of this study showed that the algorithmic models achieved an overall performance of 74.6%, with the Ada Boost algorithm leading with 83.5%. Cross-validation of the algorithms revealed an overall accuracy of 72%, with the Support Vector Classifier showing the best individual performance of 80%, indicating that this model correctly responded to 80% of the classifications in the different subsets of data. Therefore, we conclude that gait assessment, combined with machine learning algorithms, evidenced the relationship between gait characteristics and dementia, making it a safe and efficient technique for dementia classification.

AGRADECIMENTOS

Gostaria de expressar a minha sincera gratidão a todos eles que contribuíram para a conclusão deste trabalho.

Em primeiro lugar, agradeço a Deus por me dar saúde, inteligência e perseverança durante todo esse processo. Este trabalho não teria sido possível sem a sua presença constante na minha vida. A Deus seja dada toda honra e glória.

Gostaria de expressar a minha gratidão aos professores e orientadores, Dr. António Miguel de Barros Monteiro e Dr. Tiago Manuel Cabral dos Santos Barbosa, bem como ao doutorando Samuel Gonçalves Almeida da Encarnação, cuja sabedoria e crítica foram essenciais, bem como pela sua disponibilidade e atenção ao longo destes meses.

Agradeço também à minha noiva Caroline, ao meu grupo de amigos, Só Camisa10 e a todos que estiveram presentes na minha jornada, sem o apoio e incentivo deles nada disso seria possível, eles sabem que foram fundamentais durante essa fase da minha vida.

Não posso deixar de agradecer a minha mãe, Lourdes, meu pai, Daniel, minhas irmãs Daniela e Daiana, e meu irmão Rafael que infelizmente não está fisicamente presente, pois são minha base e despertam em mim a vontade de vencer para mim e para eles, além de me transmitir os principais valores da vida e despertar em mim o desejo de me tornar uma pessoa melhor a cada novo dia.

A todas estas pessoas, muito obrigado.

ÍNDICE

RESUMO.....	i
ABSTRACT.....	iii
AGRADECIMENTOS.....	iv
ÍNDICE.....	v
1. INTRODUÇÃO.....	1
2.1. Demência.....	4
2.2. Demência em idosos.....	5
2.3. Locomoção humana.....	6
2.3.1. Ciclo de marcha.....	6
2.3.2. Biomecânica da marcha humana.....	8
2.3.3. Eficiência da marcha humana.....	9
2.3.4. Deficiência em idosos e marcha humana.....	10
3. METODOLOGIA.....	11
3.1. Design do estudo.....	11
3.2. Amostra.....	11
3.3. Procedimentos.....	12
3.4. Variáveis em estudo.....	13
3.5. Análise de dados.....	14
3.5.1. Procedimentos estatísticos.....	14
3.5.2. Análise da importância das variáveis independentes (análise de correlação).....	15
3.5.3. Implementação de algoritmos de <i>machine learning</i>	15
3.5.4. Métricas de avaliação da performance dos modelos.....	20
3.5.5. Validação cruzada dos modelos.....	22
4. RESULTADOS.....	22
4.1. Estatísticas paramétricas e não paramétricas.....	22
Figura 3 – Matriz de correlação entre as variáveis independentes e a variável-alvo da classificação (demência) para todos os participantes.....	24
4.2. Algoritmos de <i>machine learning</i>	24
4.3. Validação cruzado dos algoritmos.....	26
5. DISCUSSÃO.....	27
5.1. Discussão da metodologia.....	27
5.2. Discussão dos Resultados.....	28
5.3. Aplicações.....	30
5.4. Limitações.....	31
6. CONCLUSÕES.....	32
7. REFERÊNCIAS BIBLIOGRÁFICAS.....	32
8. APÊNDICES.....	43

1. INTRODUÇÃO

O envelhecimento é o declínio irreversivelmente progressivo da função fisiológica, que ocasionalmente leva a doenças relacionadas à idade (Magalhães et al., 2017). À medida que as pessoas envelhecem passam a enfrentar condições de saúde desafiadoras, pois encontram-se numa fase da vida em que se tornam mais propensas a lidar com limitações físicas e a experimentar mudanças nas suas habilidades mentais (Cruz-Jentoft et al., 2019).

Entre essas mudanças, destaca-se o declínio cognitivo, que ocorre especialmente nas capacidades de aprendizagem e memória, relacionando-se com diversas alterações complexas no hipocampo (Bettio et al., 2017). É conhecido que áreas cerebrais semelhantes controlam a marcha e as funções cognitivas, principalmente as redes relacionadas ao lobo frontal e pré-frontal.

Também sabe-se que a diminuição dos volumes desses locais está ligada à função locomotora e afeta o estado cognitivo (Ezzati et al., 2015). As alterações mais significativas ocorrem nas atividades cognitivas que requerem o rápido processamento ou transformação da informação para a tomada de decisão, incluindo avaliações da velocidade de processamento (Murman, 2015), afetando assim as atividades diárias, como a marcha.

Com o passar dos anos, o cérebro dos idosos pode ter mais dificuldade em formar novas conexões neurais ou reparar as existentes, afetando diretamente a memória e a aprendizagem, isto devido à diminuição da capacidade de neuro plasticidade do hipocampo (D. Park & Bischof, 2011). O desequilíbrio deste processo acarreta consigo o envelhecimento cerebral e a expressão da demência (Ball & Birge, 2002).

A incidência de Demência tem aumentado progressivamente entre os idosos, segundo a Alzheimer's Disease International (2023) o número de pessoas que vivem com demência em todo o mundo deverá aumentar de 55 milhões em 2019 para 139 milhões em 2050, além de uma estimativa de que os custos associados à demência devem duplicar de US\$ 1,3 trilhão por ano em 2019 para US\$ 2,8 trilhões dólares até 2030. Portanto, a procura por uma identificação precoce é de máxima importância para proporcionar intervenções eficazes no tratamento adequado (Livingston et al., 2020; Schippinger & Pichler, 2023).

As pesquisas de Borges-Machado et al. (2021); Faieta et al. (2021) e Teri et al. (2008), indicam de maneira convincente que a intensificação da atividade física pode não só melhorar a aptidão física dos idosos e promover melhorias na funcionalidade diária, mas também melhorar o humor e retardar o avanço do declínio cognitivo. De acordo com Deschamps (2018), o movimento humano, aliado a outros sintomas clínicos, deveria ser associado como um biomarcador de transtornos mentais.

O desempenho físico está relacionado com uma função que abrange o corpo na sua totalidade, envolvendo tanto a parte sistêmica central e periférica, assim como todo o complexo músculo-esquelético. Recomenda-se a utilização da marcha como uma opção de medida

objetiva de avaliação (Beudart et al., 2019; Cruz-Jentoft et al., 2019). Investigações anteriores examinaram uma variedade de biomarcadores e avaliações cognitivas para o diagnóstico de demência, como por exemplo a síndrome de Risco Cognitivo Motor (MCR) (Verghese et al., 2014; Verghese et al., 2013).

O desempenho da marcha abaixo do ideal está associado a uma ocorrência de demência, de acordo com as conclusões de uma meta-análise conduzida por Beauchet et al. (2016). A análise de marcha é uma importante variável a ser estudada no diagnóstico de diferenciação de algumas doenças neurodegenerativas de demência, pois cada doença, como por exemplo, o Alzheimer, apresenta características únicas de deficiências de marcha (Mc Ardle et al., 2020; Mc Ardle et al., 2019).

As análises de marcha têm o intuito de auxiliar na identificação precoce de um declínio cognitivo-motor durante a fase de pré-demência, facilitando diagnósticos clínicos mais precisos e oportunos. Sendo assim, a utilização de análises de vídeo emerge como uma importante ferramenta clínica, capaz de diferenciar indivíduos saudáveis daqueles com comprometimentos cognitivos leves ou Alzheimer e ainda, apresentam a vantagem de serem uma solução de baixo custo, tornando-as acessíveis e viáveis para ampla aplicação em contextos clínicos (Silva et al., 2020).

Na elaboração de prognósticos, a utilização de modelos de predição baseados em Inteligência Artificial (IA) está a surgir como uma ferramenta útil. Estes modelos permitem antecipar a progressão da doença e proporcionam um planejamento do tratamento mais eficaz e orientado dos pacientes de uma maneira mais precisa. Isso resulta em intervenções personalizadas e melhora significativamente a gestão da saúde dos pacientes (Zucolotto et al., 2023).

Diante do exposto, considerando a necessidade de promover ideias inovadoras, acessíveis e de baixo custo para o diagnóstico precoce da demência, apresentamos os objetivos, hipóteses formuladas e a relevância/significância do estudo.

Objetivo geral

- Investigar a viabilidade de identificar e classificar o risco de Demência com base na análise das variáveis cinemáticas relacionadas com a marcha de idosos, utilizando algoritmos de *machine learning*.

Objetivos específicos

- Identificar as melhores variáveis cinemáticas da marcha para classificação da Demência.
- Realizar uma comparação entre os grupos para observar se há diferenças estatisticamente significativas nas variáveis relacionadas à marcha e desempenho cognitivo.

- Realizar a validação cruzada do modelo de algoritmos de *machine learning*.
- Avaliar métricas de desempenho dos modelos de classificação da Demência.

Hipótese Primária

- As variáveis cinemáticas da marcha identificarão e classificarão com precisão ótima e validável o risco de demência.

Hipóteses Secundárias

- Será possível identificar as melhores variáveis cinemáticas da marcha associados à demência por meio de análise da marcha.
- Existem diferenças estatisticamente significativas nas variáveis cinemáticas da marcha e no desempenho cognitivo entre os grupos analisados.
- O modelo com validação cruzada terá uma taxa de erro geral menor que 30%, garantindo um bom desempenho nas métricas de avaliação da performance dos algoritmos de *machine learning*.
- Os modelos de *machine learning* que incorporam as variáveis cinemáticas de marcha terão uma precisão superior a 70% e serão replicáveis em contextos de vida real ao classificar a demência.

Relevância/significância do estudo

- Desenvolver uma nova abordagem para a identificação precoce desta doença e permitir intervenções mais rápidas e eficazes dos pacientes.

Este estudo seguiu um procedimento estruturado em várias fases distintas e interligadas, cada uma crucial para o avanço integral da pesquisa, a saber:

- Recolha de Dados: Os dados da marcha foram obtidos pelo ciclo da marcha, através de uma caminhada a uma velocidade naturalmente selecionada, equivalente à sua velocidade diária, ao longo de uma distância de 10 metros, onde os 5 metros centrais foram utilizados para análise e gravados em vídeo, para posteriormente avaliar a eficácia da marcha. Para medir a demência, aplicou-se o questionário Mini-Exame do Estado Mental (MEEM).
- Extração das variáveis cinemáticas da marcha: A identificação e extração foram realizadas por meio de análise de vídeo, na qual foram utilizados dados de peso corporal e variáveis da marcha (tempo de voo, tempo de contato, frequência de passada, tempo em 5 metros e velocidade). Foram encontrados os valores referentes à potência metabólica, potência mecânica interna, potência mecânica externa, potência mecânica total e eficiência da marcha, bem como a remoção das amostras que não se enquadravam nos parâmetros desta pesquisa e/ou com

eventuais inconsistências.

- Desenvolvimento do Modelo: Algoritmos de *machine learning* foram treinados usando as variáveis extraídas da marcha para classificar o risco de demência.
- Avaliação e validação: O desempenho dos modelos de algoritmos de *machine learning* foram avaliados através da validação cruzada e validação do modelo preditivo através das seguintes métricas: precisão, sensibilidade, pontuação F-1 e área sobre a curva (AUC).
- Tradução Clínica: Os resultados foram interpretados e analisados, os quais serão descritos e discutidos neste trabalho, com o objetivo de compartilhar os achados, contribuindo assim para o avanço do conhecimento sobre a classificação da demência.

2. REVISÃO DA LITERATURA

2.1. Demência

De acordo com dados da Organização Mundial de Saúde (OMS), são registrados anualmente 10 milhões de novos casos de demência, com mais de 55 milhões de pessoas em todo o mundo. A demência é uma síndrome clínica caracterizada pela presença de déficits progressivos na função cognitiva, notáveis pela perda de memória, bem como pela perda de outros domínios cognitivos, como afasia, apraxia, agnosia ou distúrbios no funcionamento executivo, causando distúrbios nas atividades sociais, ocupacionais e diárias (Gallucci et al., 2005; Xu et al., 2013; Alzheimer's Disease International, 2023).

As síndromes demenciais podem ser classificadas como degenerativas, sendo aquelas que afetam o córtex e levam a uma deterioração gradual das funções cognitivas ao longo do tempo, ou não degenerativas, que podem ser causadas por acidentes vasculares cerebrais, infecções, traumas, maus hábitos nutricionais e tumores (Araújo & Nicoli, 2010). A Demência frontotemporal, a demência vascular, a demência com corpos de Lewy e a demência causada pela doença de Alzheimer estão entre as mais comuns (Afonso, 2022; Cunningham et al., 2015).

A doença de Alzheimer é uma doença neurodegenerativa progressiva, sendo uma das principais causas de demência (Beata et al., 2023), sendo responsável por 60 a 70% dos casos, segundo a Organização Mundial da Saúde (2023). O funcionamento das células nervosas (neurônios) no cérebro é afetado por esta doença. As funções relacionadas com a memória, a linguagem e o pensamento são inicialmente afetadas por esta doença, mas com o tempo afeta outras funções corporais básicas, como a locomoção e a alimentação, tornando as pessoas dependentes dos cuidados diários (Alzheimer's Disease International, 2023; Griffiths & Grant, 2023).

No estudo de Alves et al. (2024), espera-se que a prevalência de demência mais do que duplique até 2080 em Portugal, atingindo 5% da população por essa altura, mostrando a importância de colocar os cuidados com a demência como uma prioridade de saúde pública.

Com a expansão da demência, novas pesquisas estão a ser realizadas para compreender e investigar a sua prevalência e impacto na população idosa, bem como a criação de políticas públicas para mitigar e conter o problema (Y. Wu et al., 2017; Manly et al., 2022). O estágio primário de transição entre demência e estar cognitivamente intato, também conhecido como comprometimento cognitivo leve (CCL), deve ser o foco principal das intervenções primárias (Jia et al., 2020).

2.2. Demência em idosos

Com o aumento da longevidade e da esperança de vida da população, a prevalência da demência tem aumentado, apesar de não ser exclusiva dos idosos, é mais prevalente nesta população (Oh & Rabins, 2019). Um dos principais fatores de risco para a demência é a idade (Santana et al., 2015). O envelhecimento cerebral é uma das principais causas de doenças neurodegenerativas, como a doença de Alzheimer, mas o envelhecimento cerebral por si só pode causar declínio cognitivo (Ahn et al., 2022). Outras condições têm correlações significativas, como fatores psicológicos, cardiovasculares e de estilo de vida (Lara et al., 2016). Como muitos desses fatores de risco podem ser modificáveis, intervenções podem ser implementadas para reduzir o risco de institucionalização (Toot et al., 2017).

Alguns fatores de risco modificáveis para demência foram destacados num estudo de 2020 da Comissão Lancet sobre prevenção, intervenção e cuidados com a demência, a saber: hipertensão, perda auditiva, tabagismo, obesidade na meia-idade, depressão, sedentarismo, diabetes, isolamento social, consumo excessivo de álcool, traumatismo craniano e poluição do ar (Livingston et al., 2020).

Os hábitos simples, como aumentar a exposição solar e fazer exercícios, podem ajudar a retardar o declínio cognitivo em pacientes com disfunção cognitiva, especialmente em pacientes com demência (Santos et al., 2020; Huang et al., 2022). O exercício físico visando fatores de risco modificáveis e o mecanismo neuroprotetor pode reduzir a deterioração cognitiva associada ao processo normal de envelhecimento e proteger contra alterações relacionadas a doenças neurodegenerativas (Intlekofer & Cotman, 2013; Sutkowy et al., 2022)

A demência em adultos mais velhos tem um impacto significativo não só nos indivíduos afetados, mas também nas suas famílias, sendo necessárias mudanças políticas e individuais para atrasar o aparecimento de deficiências cognitivas e demência, melhores formas de apoiar e tratar as pessoas com demência e as suas famílias, bem como para diminuir a carga sobre os sistemas de saúde pública devido ao elevado custo dos cuidados e à carga emocional associada (Nakanishi et al., 2024; Nichols et al., 2022).

2.3.Locomoção humana

Dentro da natureza, a locomoção é o meio mais comum de deslocamento e, quando se trata de seres humanos, caminhar é a sua técnica mais utilizada. Com o seu estudo somos capazes de compreender e analisar os seus sistemas de funcionamento e as interações entre as funções musculares (motoras) e os arranjos do sistema de alavanca (transmissão), proporcionando assim a observação do desempenho de vários órgãos e sistemas do corpo (Peyré-Tartaruga & Coertjens, 2018).

A locomoção envolve uma série de problemas mecânicos. Para cada ciclo, os segmentos devem ser realinhados anatomicamente, incluindo as fases de aceleração e desaceleração, bem como variações no centro de elevação da massa. Caminhar e correr são partes importantes da locomoção humana e fazem parte do ciclo de vida humano (Biancardi et al., 2020).

2.3.1. Ciclo de marcha

A marcha desenrola-se em duas fases. A primeira é a fase de apoio, em que o pé está em contato com o solo; a segunda é a fase de balanço ou voo ou balanço, em que o pé não está em contato com o solo. A marcha consiste em 40% de fase de balanço e 60% de fase de apoio no tempo. Os três componentes da fase de apoio são o apoio único (do toque do calcanhar ao toque do calcanhar do pé oposto), o duplo apoio (do toque do calcanhar à elevação dos dedos) e o apoio duplo (do toque do calcanhar à elevação dos dedos, sempre do pé oposto) (Sousa, 2010; Correia, 2022; Y. Guo et al., 2022; Perry, 1992).

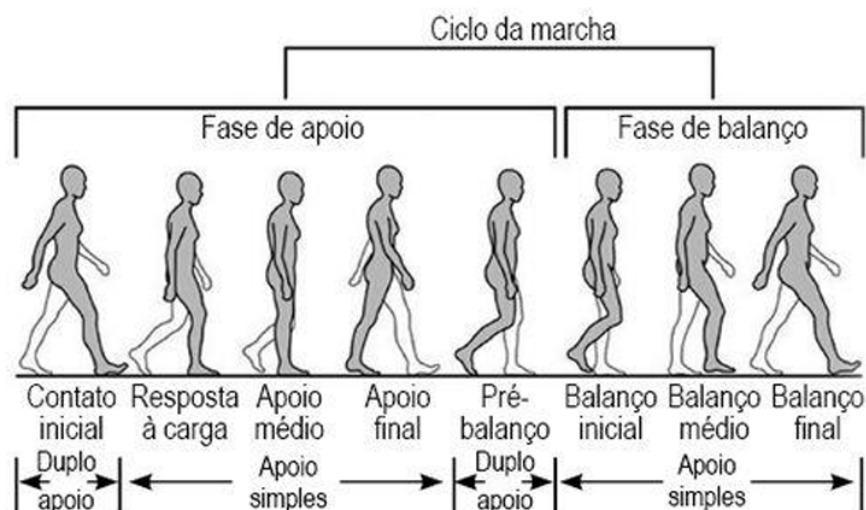


Figura 1 - Fases do ciclo da marcha (Correia, 2022).

As fases do ciclo da marcha (Luvizutto & Souza, 2020; Perry, 1992):

1. **Contato inicial:** A força de reação ao solo (FRS) empurra o joelho e a anca para trás quando o calcanhar toca o solo. Ao longo desta fase, o quadríceps não é

ativado. Em vez disso, os isquiotibiais exercem controle excêntrico sobre a extensão do joelho. O iliopsoas não tem ação e o glúteo máximo funciona excentricamente. Os dorsiflexores (parte interna: extensores tibiais anteriores e extensores do hálux; parte externa: extensores peroneais e dos dedos) atuam concentricamente para evitar que o pé caia devido à gravidade.

2. **Resposta à carga:** Nesta fase, o pé achata (com controle excêntrico), o FRS passa atrás do tornozelo, o que requer ação excêntrica dos dorsiflexores, o FRS passa atrás do joelho, o que faz com que o vasto segure para impedir a flexão, e o FRS desloca a anca para trás, fazendo com que o glúteo máximo e os isquiotibiais atuem concentricamente para estender a anca. Além disso, os adutores e glúteo médio estabilizam o joelho e a pélvis no lado oposto.
3. **Suporte médio:** A inércia ajuda a tibia a avançar, e o tríceps suralis contrai-se excentricamente para evitar que a tibia, especialmente o soleus, avance demais. Para estender o joelho, como FRS passa atrás dele e tende a flexão, ocorre a ação concêntrica do quadríceps. A pélvis é mantida estável pelo glúteo médio e adutores.
4. **Suporte final:** Nesta fase, a amplitude articular e a excursão muscular são mais importantes do que a força. Para evitar a hiperextensão do joelho, o FRS passa na frente do joelho e o gastrocnémio contrai-se excentricamente. O FRS gera extensão da anca, sem ativar o glúteo máximo, enquanto o iliopsoas controla a extensão excessiva da anca. O gastrocnémio e o iliopsoas devem ser alongados.
5. **Pré-balanço:** O FRS geralmente traz o calcanhar para baixo, ativando o tríceps suralis concentricamente. O FRS passa na frente da anca, onde o reto femoral funciona concentricamente para flexionar a anca e excentricamente para controlar a flexão do joelho. Os músculos adutores estabilizam o tornozelo e corrigem a inversão.
6. **Equilíbrio inicial:** A força da gravidade substitui o FRS. A anca é flexionada pelo iliopsoas, enquanto o joelho é flexionado pelos isquiotibiais.
7. **Balanço médio:** A flexão dorsal do tornozelo com ação concêntrica do iliopsoas ocorre quando a gravidade move o joelho de forma pendular devido à gravidade.
8. **Balanço final:** Há desaceleração do joelho com ativação concêntrica do reto femoral, o que significa flexão da anca e extensão do joelho. Os dorsiflexores preparam o apoio do calcanhar e os isquiotibiais impedem que o joelho se estenda demais.

O comprimento da passada é calculado como a distância horizontal entre dois suportes no mesmo pé. A distância medida na direção da progressão que separa o apoio inicial do pé direito do apoio do pé esquerdo é chamada de comprimento da passada esquerda, da mesma

forma, o comprimento da passada direita e a passada são os comprimentos da soma dos dois. A largura da passada é a distância entre os apoios para os pés, geralmente medida entre os pontos médios dos calcanhares. A cadência, medida em passos por minuto, é o número total de passos dados num determinado tempo. A velocidade de marcha de um corpo é a taxa de deslocamento em um determinado tempo. A velocidade média pode ser encontrada como o produto da cadência pelo comprimento da passada (Luvizutto & Souza, 2020; Whittle, 2014; Sousa, 2010).

2.3.2. Biomecânica da marcha humana

O simples ato de caminhar é uma ação complexa que envolve o aparelho locomotor (ossos, músculos e articulações). Pode ser estudada através da cinética, que engloba as forças que atuam sobre o sistema, bem como da cinemática, que descrevem os movimentos e características do corpo durante as fases da marcha, além de contar com o auxílio de sinais eletromiográficos que também auxiliam na descrição e análise do ciclo da marcha com base nos grupos musculares ativos (Loupa et al., 2020).

Cavagna et al. (1963), desenvolveram a Teoria do Pêndulo Invertido, onde explicam que a marcha humana é semelhante a um pêndulo onde a gravidade é usada para acelerar o centro de massa do corpo e a velocidade de avanço é usada para elevar novamente a distância necessária, na qual a energia cinética é transformada em energia potencial gravitacional e vice-versa. De acordo com este modelo, a energia mecânica necessária é conservada em mais de 60% a 70% (Cavagna & Margaria, 1966).




Figura 2 – Representação da Teoria do Pêndulo Invertido, adaptada de Minetti & Saibene (1992); Biancardi et al. (2020).

As energias cinéticas e potencial no modelo de pêndulo invertido, que é representado como um segmento rígido, oscilam durante a fase de postura de um membro inferior na oposição de fase. Isso faz com que as duas formas troquem energia de forma eficiente. De acordo com o modelo, o centro de massa segue uma trajetória curvilínea ao longo do ciclo, e o segmento inferior atuante funciona como um segmento rígido. Este mecanismo de flutuação de energia promove a recuperação, aproveitando a conversão de energia cinética em potencial e

vice-versa (Carvalho et al., 2015; Lee & Farley, 1998; Barbosa, 2012).

2.3.3. Eficiência da marcha humana

Durante o processo de marcha, a potência mecânica pode ser dividido em potência mecânica interna (WINT), caracterizando as flutuações de energia dos segmentos em relação ao centro de massa corporal, potência mecânica externa (WEXT), revelando-se como as flutuações de energia do centro de massa corporal em relação ao ambiente externo ou entorno e a potência mecânica total (WTOT) é o sistema para mover todos os segmentos do corpo e todo o corpo, e é calculado usando a expressão (Cavagna & Kaneko, 1977; Minetti & Saibene, 1992):

$$W_{tot} = W_{int} + W_{ext} \quad (1)$$

O modelo descrito por Minetti & Saibene (1992), para a estimativa do WINT e WEXT é desenvolvido partir das seguintes formulas:

$$W_{int} = 21,638 \times fq \times v^2 \quad (2)$$

$$W_{ext} = 10,171 \times (v^4 / fq) \quad (3)$$

Onde:

- *WINT = Potência mecânica interna (medida em W).*
- *WEXT = Potência mecânica externa (em W)*
- *fq = Frequência da passada (medida em Hz)*
- *v = Velocidade (medida em metros por segundo).*

A potência metabólica (EMET) é a energia química produzida pelo metabolismo que os músculos podem transformar em potência mecânica (W) (Biancardi et al., 2020). A hipótese proposta por Kram & Taylor (1990) afirma que a taxa de energia consumida pelos músculos é proporcional à taxa de peso corporal (BM) expressa em Newtons (BW), ao tempo de contato (tc) e ao coeficiente de custo de 0,183. Isto resulta na seguinte fórmula EMET:

$$E_{met} = 0.183 * (1/tc) * BW \quad (4)$$

Onde:

- *tc = Tempo de contato (medida em segundos).*
- *BW = Peso corporal (medida em Newtons).*

A eficiência da marcha (Em) pode ser definida como a relação entre a potência mecânica realizado pelo corpo e a potência metabólica consumida durante a locomoção, verificou-se que em jovens e saudáveis na marcha com velocidades médias, a eficiência atinge cerca de 35 a 40 %, enquanto em velocidades mais elevadas, como a corrida, pode atingir 70 a 80 %, o cálculo para isso é demonstrado através de (Cavagna & Kaneko, 1977):

$$Em = W^{tot}/E_{met} \quad (5)$$

Conforme as pesquisas de Luciano et al. (2023) e Farris & Sawicki (2012), para velocidades acima de 1,0 m/s em jovens saudáveis, os valores da eficiência da marcha estão próximos de 30% e aumentam à medida que a velocidade aumenta. Mian et al. (2006), relatam que os idosos têm taxas de eficiência inferiores em relação aos jovens, o que pode ser justificado por um custo metabólico mais elevado, tendo como possíveis motivos a maior necessidade de forças isométricas e a ativação conjunta da musculatura antagonista para estabilização. Ademais, a efetividade de caminhar a uma velocidade normal está associada a uma correlação negativa com a gordura corporal, tanto em homens quanto em mulheres (Chen et al., 2004). Além disso, o uso de muletas resulta em um consumo energético de 2 a 3 vezes maior do que em uma caminhada comum, resultando em uma diminuição da eficiência do trabalho (Thys et al., 1996).

A marcha, feita com passadas apropriadas para cada pessoa, parece ser o método mais eficaz para reduzir a potência mecânica que os músculos precisam fazer e maximizar sua eficiência (Umberger & Martin, 2007). Portanto, mesmo que a corrida seja mais eficiente, a escolha da marcha é a forma mais adequada de economizar energia, essa otimização pode direcionar as energias disponibilizando-as para o nosso crescimento e reprodução, conforme defendido no trabalho de Alexander (2003), sobre os Princípios da locomoção animal.

2.3.4. Deficiência em idosos e marcha humana

O desempenho da marcha é afetado pela neurodegeneração associada ao envelhecimento e pode ser usado como um indicador de progressão de comprometimento cognitivo leve e demência (Montero-Odasso et al., 2017). O uso da marcha como ferramenta para a detecção de doenças neurodegenerativas, como a doença de Parkinson, está a ser utilizada e tem apresentado bons resultados, e tem sido proposto o desenvolvimento de biomarcadores objetivos baseados na marcha para suporte e tratamento individualizados (Guo et al., 2022).

Deficiências cognitivas são mais comuns entre indivíduos com comprometimento da marcha, e tais distúrbios da marcha podem ser medidos anos antes de comprometimento cognitivo leve, demência ou dificuldades de mobilidade se manifestarem clinicamente (Bridenbaugh & Kressig, 2014). O declínio motor, estudado através da diminuição da velocidade de marcha, apresentou um elevado risco atribuível de demência (Collyer et al., 2022; Montero-Odasso et al., 2018). Assim, as pesquisas de marcha e cognição são válidas para avaliar o risco de demência (Doi et al., 2018).

A marcha das pessoas com demência apresenta um padrão mais variado. O uso da polifarmácia relacionada à deficiência também promove essas alterações, apresentando menor

comprimento de passo e maior tempo de duplo apoio, o que pode indicar a tentativa de uma marcha mais cautelosa para promover um melhor equilíbrio (Maas et al., 2020).

As limitações de mobilidade acentuam-se com o avançar da idade, devido à redução da força muscular, por exemplo, provocando a perda de capacidades funcionais diárias, especialmente quando associadas a uma doença debilitante (Grimmer et al., 2019). A falta de independência funcional associada ao declínio cognitivo e à demência promovem maior risco de quedas em idosos (Cavalcanti, 2023; Izzo et al., 2022). Para prever o risco de quedas em idosos com alta certeza, pode-se recrutar uma avaliação individual da mobilidade funcional, equilíbrio ou marcha (Beck Jepsen et al., 2022), além disso, é necessário promover o uso de exercícios físicos para melhorar as capacidades físicas e funcionais, como equilíbrio e coordenação, possibilitando uma melhor qualidade de vida (Dunsky, 2019; Borgo, 2021).

3. METODOLOGIA

3.1.Design do estudo

Esta investigação é um estudo observacional transversal, que visa descobrir quais as variáveis cinemáticas da marcha mais adequados para classificar a demência. Usando a análise da marcha gravada em vídeo e algoritmos de *machine learning* para aprender padrões a partir de dados e avaliar a replicabilidade e precisão do modelo na vida real.

3.2.Amostra

Os procedimentos para o desenvolvimento do estudo incluíram, primeiramente, o estudo foi aprovado pelo Comité de Ética do Instituto politécnico de Bragança (IPB), com o número de processo 501020, e faz parte de um projeto de pesquisa maior intitulado “Efeitos do treino multicomponente no risco de doença de alzheimer, aptidão funcional e bem-estar de idosas fisicamente ativas”, que teve seu início em 2023.

Posteriormente ocorreu a seleção dos participantes, que foram admitidos com base nos critérios de inclusão, onde deveriam ter idade igual ou superior a 55 anos, não deveriam apresentar distúrbios psicológicas ou físicos que prejudicassem o desempenho durante os testes, bem como deficiências visuais e/ou auditivas críticas que possam afetar a marcha, bem como o uso de dispositivos auxiliares para a marcha ou dificuldade evidente em realizar tarefas da vida diária.

Para o critério de exclusão, ter idade inferior ou igual a 54 anos, apresentar distúrbios psicológicas ou físicos que prejudicassem o desempenho durante os testes, apresentar deficiências visuais e/ou auditivas críticas que possam afetar a marcha, bem como fazer o uso de dispositivos auxiliares durante a avaliação da marcha ou apresentar dificuldade evidente em realizar tarefas da vida diária.

Os grupos foram pareados em dois grupos sendo um de idosos institucionalizados e

outro de idosos não institucionalizados. Os indivíduos que preencheram os critérios definidos foram selecionados de forma não probabilística, todos os participantes foram informados sobre os riscos e desconfortos potenciais, além da concordância em participar do estudo por meio do termo de consentimento livre e esclarecido.

A amostra foi constituída por 59 participantes, com 60 ± 8 anos de idade [56 (95%) \geq 65 anos], massa corporal de 60 ± 10 kg, com 17 homens e 42 mulheres. Foram selecionados 33 idosos que participam do projeto social para idosos da comunidade de Bragança, um grupo de investigação em exercício físico e envelhecimento ativo denominado “MAIS IDADE MAIS SAÚDE” realizado no Instituto Politécnico de Bragança (IPB), intitulamos como o Grupo não Institucionalizado (GNI), o outro grupo intitulado como grupo institucionalizado (GI) foi composto por 26 idosos pertencentes a Santa Casa da Misericórdia de Bragança.

3.3.Procedimentos

Para avaliar o estado cognitivo, foi aplicado um questionário a todos os participantes, do qual foi utilizado o Mini Exame do Estado Mental (MEEM), conforme descrito abaixo:

3.3.1. Mini Exame do Estado Mental (MEEM):

As respostas ao MEEM foram avaliadas e analisadas para compreender o estado cognitivo dos participantes. Mini Exame do Estado Mental, versão portuguesa de Guerreiro et al. (1994). O MEEM é uma escala de alta confiabilidade em inglês e português. O questionário contém 11 itens que avaliam as seguintes habilidades cognitivas: orientação espacial e temporal (capacidade de se situar corretamente no tempo e no espaço), por exemplo, —em que data estamos?ll, retenção (memória de curto prazo, consolidação de novas informações), por exemplo, —Vou dizer 3 palavras; Eu gostaria que você os repetisse...ll, atenção e cálculo (a capacidade de alcançar um grau de concentração para responder a perguntas de cálculo, a memória operacional é o sistema de controle de atenção) por exemplo, —Eu peço que você me diga quantos são 30 menos 3 e, em seguida, o número que você encontrar leva 3 novamente...ll, evocação (a capacidade de recuperar informações da memória, Consiste em um esforço intelectual) —veja se você pode dizer as palavras que você disse há pouco...ll, linguagem (memória semântica, conhecimento geral sobre o mundo, de fatos, de palavras, sem relação com o momento de sua aprendizagem) —como isso se chama?ll e capacidade construtiva (operação cognitiva de como a informação está sendo registrada) por exemplo —você deve copiar um desenho...ll. Portanto, este questionário é seguro e não apresenta perguntas desagradáveis, inoportunas ou sensíveis aos participantes. A pontuação máxima no MEEM é de 30 pontos, sendo sua classificação de 24 a 30 pontos considerada normal ou cognitivamente intacta; 18 a 23 pontos indicando possível comprometimento cognitivo leve e 0 a 17 relacionados a comprometimento cognitivo moderado a grave.

3.3.2. Biomecânica da Marcha

Os dados de marcha foram recolhidos em um espaço plano e regular, onde os participantes eram orientados a utilizar roupa e calçado que lhe fossem confortáveis e não limitassem seus movimentos. A recolha de dados de marcha foi realizada de forma segura e controlada, com a velocidade adequada para cada participante. Foi solicitado ao participante que caminhasse a uma velocidade naturalmente selecionada, semelhante à sua velocidade diária. A distância percorrida foi de 10 metros e os 5 metros centrais foram usados para medir o ciclo da marcha, e os 2,5 metros foram usados para recuos anteriores e posteriores. Foi um exercício de baixa intensidade com duração média de 5 a 15 segundos. No início das recolhas foram obtidos os dados de característica antropométrica: massa corporal, sexo, idade.

O registo foi feito em vídeo de alta-definição através de um iPhone 12, usando o modo de câmara lenta com uma taxa de quadros de vídeo de 120 FPS (fotogramas por segundo). Os vídeos foram processados e analisados utilizando o software Kinovea para extrair as variáveis da marcha. Os dados de massa corporal e variáveis cinemáticas da marcha (tempo de voo, tempo de contato, frequência de passada e velocidade) foram adotados para estimar a potência mecânica através do modelo descrito por Minetti & Saibene (1992) (equações 1,2,3) e do modelo de Kram & Taylor (1990) para a estimativa da potência metabólica (equação 4). Deste modo como uso destas duas variáveis foi possível calcular o valor referente a Eficiência da marcha (equação 5) como descrito por Cavagna & Kaneko (1977).

Após a obtenção de todos os dados cognitivos e de marcha, foram feitas verificações para garantir a consistência e remover amostras inconsistentes, depois de tudo verificado foi enviado para as análises, onde foi utilizado o PythonTM, uma linguagem de programação computacional, e foi realizado um modelo de classificação através de algoritmos *machine learning* para classificar o risco de demência associado as variáveis cinemáticas da marcha.

3.4. Variáveis em estudo

As variáveis em estudo referem-se a três aspetos:

1. Dados antropométricos:

- Idade (em anos): número de anos completos desde o nascimento do participante;
- Massa corporal (em kg): o peso total do corpo em quilogramas, medido numa balança;
- Peso em Newtons (N): força gravitacional que atua sobre o corpo, calculada como o produto da massa corporal (em kg) pela aceleração da gravidade ($9,81 \text{ m/s}^2$).

2. Função cognitiva:

- Dados dos resultados do MEEM, com pontuação de 0 a 30.

3. Variáveis cinemáticas da marcha

- Tempo em 5 metros (em s): tempo que o participante levou para percorrer uma distância de 5 metros;
- Velocidade (em m/s): taxa de deslocamento linear, calculada como a distância percorrida dividida pelo tempo;
- Tempo de contacto (em s): duração do período em que o pé está em contacto com o solo durante cada passo;
- Tempo de voo (em s): duração do período em que o pé está fora do solo, até tocar novamente no solo;
- Frequência de passada (em Hz): número de passos realizados por unidade de tempo;
- Poder metabólico (em W): taxa de energia consumida pelo corpo para sustentar a marcha, reflete o custo energético do movimento;
- Potência mecânica interna (em W): energia gerada para mover as partes do corpo em relação ao centro de massa (movimentos internos, como os dos membros);
- Potência mecânica externa (em W): energia gerada para deslocar o centro de massa do corpo em relação ao ambiente externo;
- Potência mecânica total (em W): soma da potência mecânica interna e externa, representando a energia total gerada durante a marcha;
- Eficiência da marcha (adimensional ou percentual): relação entre a potência mecânica total e a potência metabólica, mede a eficiência energética da marcha.

A análise dessas variáveis ajudou a entender melhor as diferenças nas variáveis da marcha entre os idosos, assim como nos ajudou a entender melhor o estado cognitivo de cada grupo e determinar quais variáveis em conjunto poderiam ter uma associação com a demência.

3.5. Análise de dados

3.5.1. Procedimentos estatísticos

Todas as análises desse estudo foram desenvolvidas em Python™, linguagem de programação computacional (*Python.Org*, 2024). Os dados foram reportados em média e desvio padrão e valores percentuais (Cohen, 2013). Inicialmente, as funções `“import pandas as pd”`, `“from scipy.stats import shapiro”`, `“from scipy.stats import ttest_ind”`, `“from scipy.stats import mannwhitneyu”`, sendo ativadas para os cálculos estatísticos. A normalidade dos dados foi

testada por meio do teste de Shapiro-Wilk, considerando um intervalo de confiança de 95% ($p < 0,05$) para diferenças entre os valores das variáveis analisadas, assim, considerando não paramétricos aquelas variáveis com diferença significativa para o teste de normalidade (Cohen, 2013). Assim, para os dados paramétricos, foi aplicado o teste T de student para amostras independentes, e quando os dados foram não paramétricos, o teste de Mann-Whitney-Wilcoxon (U) foi aplicado. Para ambos os teste, o nível de significância foi adotado num intervalo de confiança de 95% ($p < 0,05$) (Cohen, 2013; Haslwanger, 2016). Para as comparações com diferenças significantes, o tamanho de efeito d de Cohen foi aplicado, considerando os limiares de 0,20 = pequeno, 0,50 = moderado, e 0,80 = grande, para interpretação clínica (Sullivan & Feinn, 2012).

3.5.2. Análise da importância das variáveis independentes (análise de correlação)

Inicialmente, as funções “import pandas as pd” foi ativada para a transformação das variáveis em formato framework de dados para arrays (Mckinney, 2011). Foi conduzida uma análise de importância das variáveis independentes, para reduzir a dimensionalidade do conjunto de dados, reduzir o ruído dos dados para as seguintes equações de classificação, e melhorar o desempenho dos algoritmos (Cai et al., 2018). Para isso, uma matriz de correlação foi realizada, considerando o coeficiente de correlação (r) como medida de associação entre as variáveis independentes e a variável-alvo para classificação, a identificação da demência (Sim = 1, Não = 0) usando o MMSE, Figura 3 (Ibrahim et al., 2021) . Os tamanhos de efeito de r, foram considerados 0,20 = pequeno, 0,50 = moderado, e 0,80 = grande (Ferguson, 2009), sendo somente moderados ($\geq 0,50$) coeficientes de correlação foram considerados para constituírem a análise principal de classificação da demência nos participantes. Com isso, apenas as seguintes variáveis foram consideradas para a implementação dos algoritmos: idade ($r = 0,51$), potência mecânica total ($r = -0,63$), potência mecânica externa ($r = -0,61$), potência mecânica interna ($r = -0,62$), tempo na caminhada de 5 metros ($r = 0,59$), velocidade da marcha ($r = -0,62$), e percentual de eficiência da marcha ($r = -0,59$).

3.5.3. Implementação de algoritmos de *machine learning*

Foram escolhidos os algoritmos de classificação, devido ao fato da variável alvo ser caracterizada como binária (Galdino, 2020). Após isso, dois arrays foram construídos, sendo o *array X* constituídos com as variáveis independentes selecionadas, e o *array y*. Após a definição dos *arrays* a função “*from sklearn.preprocessing import StandardScaler*” foi ativada para a realização do processo de normalização do *array X* para uma escala de grandeza -1 a 1, assim determinando pesos iguais para todas as variáveis independentes em caracterizar a demência nos participantes (D. Singh & B. Singh, 2020; Hao & Ho, 2019). Apesar das correlações inicialmente identificadas, somente um painel de cinco variáveis independentes apresentou o

mais alto desempenho em classificar a demência nos participantes, sendo a idade, a potência mecânica interna, o tempo na caminhada de 5 metros, a potência mecânica externa, e o percentual de eficiência da marcha. Ativando a função "train_test_split" O *array X* comportou 70% dos dados para o treino dos algoritmos (n = 164 características de 41 participantes), e o *array y* ficou com 30% do conjunto de dados para a testarem e validação dos algoritmos (variável dependente–alvo da classificação, n = 18 participantes com classes 0 ou 1) (Hao & Ho, 2019; Unpingco, 2016). Uma semente randômica (*seed* = 0) foi determinada para todos os algoritmos, para garantir que a forma de repartimento dos dados para treino e teste sempre seguisse o mesmo processo de aleatorização, assim, eliminando o viés de alocação das observações para os conjuntos de treino e teste (Kaczmarczyk & Miałkowska, 2022).

Com isso, os seguintes algoritmos foram considerados para a classificação da demência baseado em variáveis cinemáticas de marcha dos idosos:

- **Naive Bayes**

O classificador Naive Bayes foi implementado por meio da função "*from sklearn.naive_bayes import GaussianNB*" (Pedregosa et al., 2011). Naive Bayes é um classificador probabilístico que se baseia no Teorema de Bayes com a suposição de independência entre as características de diferentes classes. Este algoritmo é simples e eficiente para lidar com problemas de classificação. A principal vantagem do Naive Bayes é sua capacidade de lidar com rapidez tanto com conjuntos de dados maiores e reduzidos (*Naive Bayes Classifier, 2023*), como compreendido pela seguinte equação:

$$\sigma(z) = \frac{P(X|Y)P(Y)}{P(X)}$$

Onde, para a proposição deste teorema, Y e X são considerados como:

- P(Y), a "probabilidade a priori", é o grau inicial de crença em Y.
- P(Y|X), a "probabilidade a posteriori", é o grau de crença após considerar X. É interpretada como "a probabilidade de Y, dado que X é o caso".
- O quociente P(X|Y) /P(X) representa o suporte que X fornece para Y.

Com isso, devido à sua simplicidade e precisão ao trabalhar com pequenos conjuntos de dados, este modelo é considerado adequado à demandas de investigação no campo das ciências da saúde, levando a diagnósticos e classificações precisos e fiáveis (H. Zhang & Su, 2008).

- **Regressão Logística**

A regressão logística foi realizada por meio da ativação da função “*from sklearn.linear_model import LogisticRegression*” (Pedregosa et al., 2011). A regressão logística é um modelo clássico para a previsão de problemas de natureza binária (duas classes). Ela utiliza a função sigmoide para converter características lineares numa probabilidade. Esse tipo de modelo é tem aplicabilidade na classificação em ambas ciências exatas e biológicas (T. Wu et al., 2023). A equação a seguir caracteriza a Regressão logística:

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$

Onde:

- $\sigma(z)$ representa a função logística.
- e é a base do logaritmo natural.
- z é a combinação linear das características de entrada e seus pesos correspondentes, frequentemente denotados como $z = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n$.

Na regressão logística, o log-odds (logaritmo da razão de probabilidades) é modelado para representar a probabilidade de um dado input x pertencer à classe positiva (Starbuck, 2023). Os log-odds são denotados como $\text{logit}(p)$, onde p é a probabilidade de x pertencer à classe positiva, descrito na equação:

$$\text{logit}(p) = \log\left(\frac{p}{1-p}\right) = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n$$

Onde:

- $w_0, w_1, w_2, \dots, w_n$ são os coeficientes (pesos) do modelo de regressão logística.
- x_1, x_2, \dots, x_n são as características de entrada
- p é a probabilidade de x pertencer à classe positiva.
- $1-p$ é a probabilities de x pertencer à classe negativa.

- **Floresta Randômica (Random Forest)**

A Floresta Randômica foi aplicada por meio da ativação da biblioteca “*from sklearn.ensemble import RandomForestClassifier*” (Pedregosa et al., 2011). Este modelo é um método de ensemble que se baseia em múltiplas árvores de decisão para melhorar a precisão das suas previsões e com isso reduzir o risco de *overfitting* nos dados previstos. Cada árvore é treinada em diferentes subconjuntos de dados e características. A maioria de previsões semelhante entre as árvores é tomada como previsão final das classes pelo modelo (Breiman, 2001), determinado na seguinte equação:

$$\hat{y} = \frac{1}{N} \sum_{i=1}^n y_i$$

Onde y denota o valor previsto, N representa o número total de árvores de decisão no conjunto, e y_i significa a previsão feita por cada árvore individual.

- **Classificador de Vetores de Suporte (SVM)**

O classificador de Vetores de Suporte (SVM) foi implementado por meio da ativação da biblioteca “*from sklearn.svm import SVC*” (Pedregosa et al., 2011). O SVM encontra o hiperplano que maximiza a margem entre classes no espaço das características da amostra. Para dados não linearmente separáveis, SVM utiliza funções kernel para mapear os dados para um espaço dimensional mais alto onde a separação linear é possível. Este modelo é eficaz em espaços de alta dimensão, assim sendo poderoso para decidir com conjuntos de dados complexos e ou onde o investigador não tem amplo conhecimento sobre as características, ou influências de variáveis independentes (Cervantes et al., 2020). O SVM é definido pela seguinte equação:

$$f(x) = w \cdot x + b$$

- W é o vetor de pesos.
- X é o vetor de características da amostra.
- b é o termo de *bias* (ou intercepto).

- **Classificador K-Nearest Neighbors (KNN)**

O classificador K-Nearest Neighbors (KNN) foi implementado por meio da ativação da biblioteca “*from sklearn.svm import SVC*” (Pedregosa et al., 2011). KNN classifica um ponto de dados baseado nas classes dos seus k vizinhos mais próximos, medidos por uma métrica chamada Distância Euclidiana. É simples, não paramétrico e eficaz para problemas de classificação e regressão (Z. Zhang, 2016), como defina na equação:

$$Distância\ Euclidiana = \sqrt{\sum_{i=1}^n (x_{1,i} - x_{2,i})^2}$$

Onde:

- $x_{1,i}$: representa a i -ésima coordenada do primeiro ponto.
- $x_{2,i}$: Isto representa a i -ésima coordenada do segundo ponto.

Ao elevar ao quadrado a diferença, garantimos que as diferenças negativas não anulem as diferenças positivas ao somar.

- **Árvore de Decisão**

Os algoritmos de Árvores de Decisão utilizam uma estrutura hierárquica para dividir iterativamente o espaço das características em subconjuntos homogêneos. Cada nó representa uma decisão sendo baseado numa característica, e cada folha representa um valor de classificação (positivo = 1, ou negativo = 0) (Song & Lu, 2015). A árvore de decisão trabalha por meio da seguinte equação:

$$\hat{y} = \frac{1}{N} \sum_{i=1}^n \sum^i y_i$$

Crítérios comuns para divisão são a entropia ou o índice de Gini:

Onde:

- \hat{y} representa o valor previsto, que é a média dos valores observados de y .
- N é o número total de observações.
- y_i é o valor observado para a i -ésima observação.

- **Classificador Gradient Boosting**

O classificador K-Nearest Neighbors (KNN) foi implementado por meio da ativação da biblioteca “`from sklearn.neighbors import KNeighborsClassifier`” (Pedregosa et al., 2011). Este algoritmo cria um modelo preditivo forte combinando vários modelos fracos (geralmente árvores de decisão) sequencialmente. Cada modelo subsequente é ajustado para corrigir os erros dos modelos anteriores, minimizando uma função de perda usando gradientes, os quais são derivadas que indicam os limites onde a equação não tem mais perda, ou seja, alcançou a aprendizagem máxima para a classificação (Natekin & Knoll, 2013). Isso pode ser observado na equação a seguir:

$$f_m(x) = F_{m-1}(x) + \gamma_m h_m(x)$$

Onde:

- $f_m(x)$ é o modelo da iteração m .
- $F_{m-1}(x)$ é o modelo acumulado até a iteração $m - 1$.
- γ_m é a taxa de aprendizado ou peso do modelo fraco na iteração m .
- $h_m(x)$ é o modelo fraco na iteração m .

- **Classificador AdaBoost**

O classificador *AdaBoost* foi aplicado por meio da ativação da biblioteca “`from sklearn.ensemble import GradientBoostingClassifier, AdaBoostClassifier`” (Pedregosa et al., 2011). Este modelo trabalha combinando múltiplos modelos

fracos ajustando os pesos das observações para focar nos exemplos mais difíceis. Cada modelo fraco é treinado sequencialmente, contribuindo com um peso proporcional à sua precisão. A predição final é uma combinação ponderada dos modelos fracos, ou seja, ponderando os pesos de todos os modelos e aferindo uma acurácia mais ajustada para a classificação final (Wang, 2012). A equação seguinte define o classificador *AdaBoost*.

$$f(x) = \sum_{i=1}^M \alpha_m h_m(x)$$

- α_m é o peso do modelo fraco m .
- $h_m(x)$ é o modelo fraco m .
- M é o número total de modelos fracos.

- **Classificador XGBoost**

O classificador XGBoost foi utilizado por meio da ativação da biblioteca “*from xgboost import XGBClassifier*” (Pedregosa et al., 2011). O XGBoost é uma versão otimizada do Gradient Boosting, incorporando regularização e paralelização para melhorar a precisão e a velocidade do modelo classificatório. Esse algoritmo usa árvores de decisão como modelos fracos, e usa o método de *boosting* onde as árvores a frente, corrigem o erro das árvores anteriores. Esse modelo trabalha com alta eficiência em conjuntos de dados com alta dimensionalidade, pois consegue dividir o seu trabalho por vários núcleos de processamento, assim, reduzindo o tempo para classificação (Tarwidi et al., 2023). A equação a baixo explica o modelo.

$$\hat{y} = \sum_{i=1}^M \gamma \cdot h_i(x)$$

Onde:

- \hat{y} denota o valor previsto.
- M representa o número total de modelos sequenciais do conjunto (geralmente árvores de decisão).
- γ significa a taxa de aprendizado, que controla a contribuição de cada modelo para a previsão final.
- $h_i(x)$ representa a previsão feita por cada modelo i para os dados de entrada x .

3.5.4. Métricas de avaliação da performance dos modelos

- **Acurácia**

A acurácia mede a proporção de instâncias classificadas corretamente entre

todas as instâncias. Ela é calculada como a proporção do número de instâncias previstas corretamente (verdadeiros positivos e verdadeiros negativos) relativamente ao número total de instâncias (Hicks et al., 2022).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Onde:

- TP = True positives
- TN = True negatives
- FP = False positives
- FN = False negatives

- **Sensibilidade**

A sensibilidade, também conhecida como recall ou taxa de positivos verdadeiros, mede a proporção de instâncias positivas reais que o modelo prevê corretamente. Ela é calculada como a proporção de verdadeiros positivos relativamente à soma de verdadeiros positivos e falsos negativos (Hicks et al., 2022).

$$Sensibilidade = \frac{TP}{TP + FN}$$

- **Precisão**

A precisão mede a proporção de instâncias positivas previstas classificadas corretamente. Ela é calculada como a proporção de verdadeiros positivos relativas à soma de verdadeiros positivos e falsos positivos (Hicks et al., 2022):.

$$Precisão = \frac{TP}{TP + FP}$$

- **F-1 Score**

A pontuação F (F-score) é a média harmónica da precisão e da sensibilidade (recall), fornecendo uma métrica única que equilibra ambas as medidas. É calculada utilizando os valores de precisão e sensibilidade, combinando-os num único valor (Hicks et al., 2022).

$$F - 1 \text{ score} = 2 \times \frac{PPV \times Se}{PPV + Se}$$

- **Curva ROC ou AUC**

A curva ROC (Receiver Operating Characteristic) é um gráfico que mostra a relação entre a taxa de verdadeiros positivos (Sensibilidade) e a taxa de falsos

positivos em vários limiares de decisão (Bradley, 1997), revendo as equações de sensibilidade e da taxa de falsos positivos:

$$\text{Sensibilidade} = \frac{TP}{TP + FN}$$

$$\text{Taxa de falsos positivos} = \frac{FP}{FP + TN}$$

3.5.5. Validação cruzada dos modelos

Para a validação cruzada dos resultados dos algoritmos foi utilizado o método de *K-folds cross-validation*. Este algoritmo trabalha dividindo o conjunto de dados em *K* subconjuntos, e em cada iteração do modelo, cada *K* subconjuntos são utilizados como teste e os *K* subconjuntos restantes são usados como treino (Wong, 2015). Assim, é possível obter um panorama específico do desempenho dos modelos ao longo de todas as subpartes do conjunto de dados (Wong, 2015). Como métricas de desempenho, foram utilizadas a acurácia média, e acurácia absoluta para cada *K* subconjunto e desvio padrão acurácia média (Wong, 2015).

4. RESULTADOS

4.1. Estatísticas paramétricas e não paramétricas

A tabela 1 mostra a estatística descritiva para os dois grupos envolvidos no estudo. Foram observadas diferenças estatisticamente significativas indicando superioridade com tamanhos de efeito grandes, do grupo não institucionalizados (GNI) em relação o grupo institucionalizado (GI) nas variáveis, idade, tempo nos 5 metros, velocidade da marcha, potência mecânica interna, potência mecânica externa, potência mecânica total, eficiência da marcha, e pontuação no MMSE, assim como no tempo de contato porem com tamanho de efeito pequeno.

Tabela 1. Características da amostra.

	GI (n = 26) Media +/- DP (95IC)	GNI (n = 33)	t- estat	pt	U- estat	pU	Cohen's d
Idade (anos)	82,19 ± 7,86 (79,17; 85,21)	71,66 ± 4,78 (70,03 – 73,29)	6,34	<0.001	NA	NA	1,62
Massa corporal (kg)	65,05 ± 9,57 (61,37 – 68,73)	64,84 ± 11,65 (60,87 – 68,82)	0,07	0,93	NA	NA	0,02
Peso corporal (N)	638,21 ± 93,93 (602,10 – 674,31)	636,10 ± 114,34 (597,09 – 675,11)	0,07	0,94	NA	NA	0,02
Tempo nos 5 metros	5,59 ± 1,15 (5,15 – 6,03)	3,97 ± 0,32 (3,86 – 4,08)	7,70	<0.001	NA	NA	1,92
Velocidade (m/s)	0,93 ± 0,20 (0,85 – 1,01)	1,26 ± 0,10 (1,23 – 1,29)	8,35	<0.001	NA	NA	-2,09

Tempo de contato (s)	0,66 ± 0,08 (0,63 – 0,69)	0,63±0,05 (0,61 – 0,65)	2,11	0,03	NA	NA	0,45
Tempo de voo (s)	0,35 ± 0,039 (0,335 – 0,365)	0,35 ± 0,031 (0,34 – 0,36)	NA	NA	435	0,93	0
Frequência da passada (Hz)	0,99 ± 0,12 (0,94 – 1,04)	1,02 ± 0,08 (0,99 – 1,05)	NA	NA	308	0,06	-0,29
Potência metabólica (W)	176,67 ± 31,5 (164,56 – 188,78)	185,35 ± 32,65 (174,21 – 196,49)	NA	NA	375	0,41	-0,27
Potência mecânica interna (W)	19,51 ± 9,20 (15,97 – 23,05)	35,79 ± 6,55 (33,56 – 38,03)	NA	NA	69	<0.001	-2,04
Potência mecânica externa (W)	10,16 ± 10,10 (6,28 – 14,04)	26,67 ± 7,85 (23,99 – 29,35)	NA	NA	76	<0.001	-1,83
Potência mecânica total (W)	29,67 ± 18,9 (22,41–36,94)	62,46 ± 13,57 (57,83 – 67,09)	NA	NA	77	<0.001	-1,99
Eficiência da marcha (adimensional)	0,1661 ± 0,0848 (0,134 – 0,199)	0,3396 ± 0,0516 (0,322 – 0,357)	NA	NA	48.5	<0.001	-2,47
MMSE (u.a.)	18,53 ± 5,17 (16,54 – 20,52)	26,18 ± 2,83 (25,21 – 27,15)	NA	NA	63	<0.001	-1,84

Nota: GI: grupo institucionalizado, GNI: grupo não institucionalizado, t-estat: estatística para o teste t independente, pt: valor de p para o teste t independente, U-estat: estatística para o teste de Mann-Whitney-Wilcoxon, pU: valor de p para o teste de Mann-Whitney-Wilcoxon, NA: não-aplicável, Cohen's d: tamanho do efeito.

A Figura 3 mostra a matriz de correlação, demonstrando as conexões entre as variáveis independentes e a variável de interesse (demência), destacando os elementos que exercem maior influência no risco de demência. Variáveis relacionadas à marcha, como redução da potência mecânica interna ($r = -0,62$), externa ($r = -0,61$) e total ($r = -0,63$), bem como redução da velocidade da marcha ($r = -0,62$) e da eficiência da marcha ($r = -0,59$), aumento da idade ($r = 0,51$) e do tempo de caminhada de 5 metros ($r = 0,59$) foram as variáveis da marcha que apresentaram as correlações mais relevantes com a demência. Por meio dessas correlações, foi estabelecido um conjunto de cinco variáveis independentes para classificar a demência nos participantes, que incluem idade, potência mecânica interna, tempo gasto em uma caminhada de 5 metros, potência mecânica externa e a eficiência da marcha. A escolha dessas variáveis foi feita porque o uso de todas as variáveis poderia sobrecarregar e gerar confusão nos algoritmos de classificação, uma vez que algumas dessas variáveis estão correlacionadas e expressam o mesmo conceito.

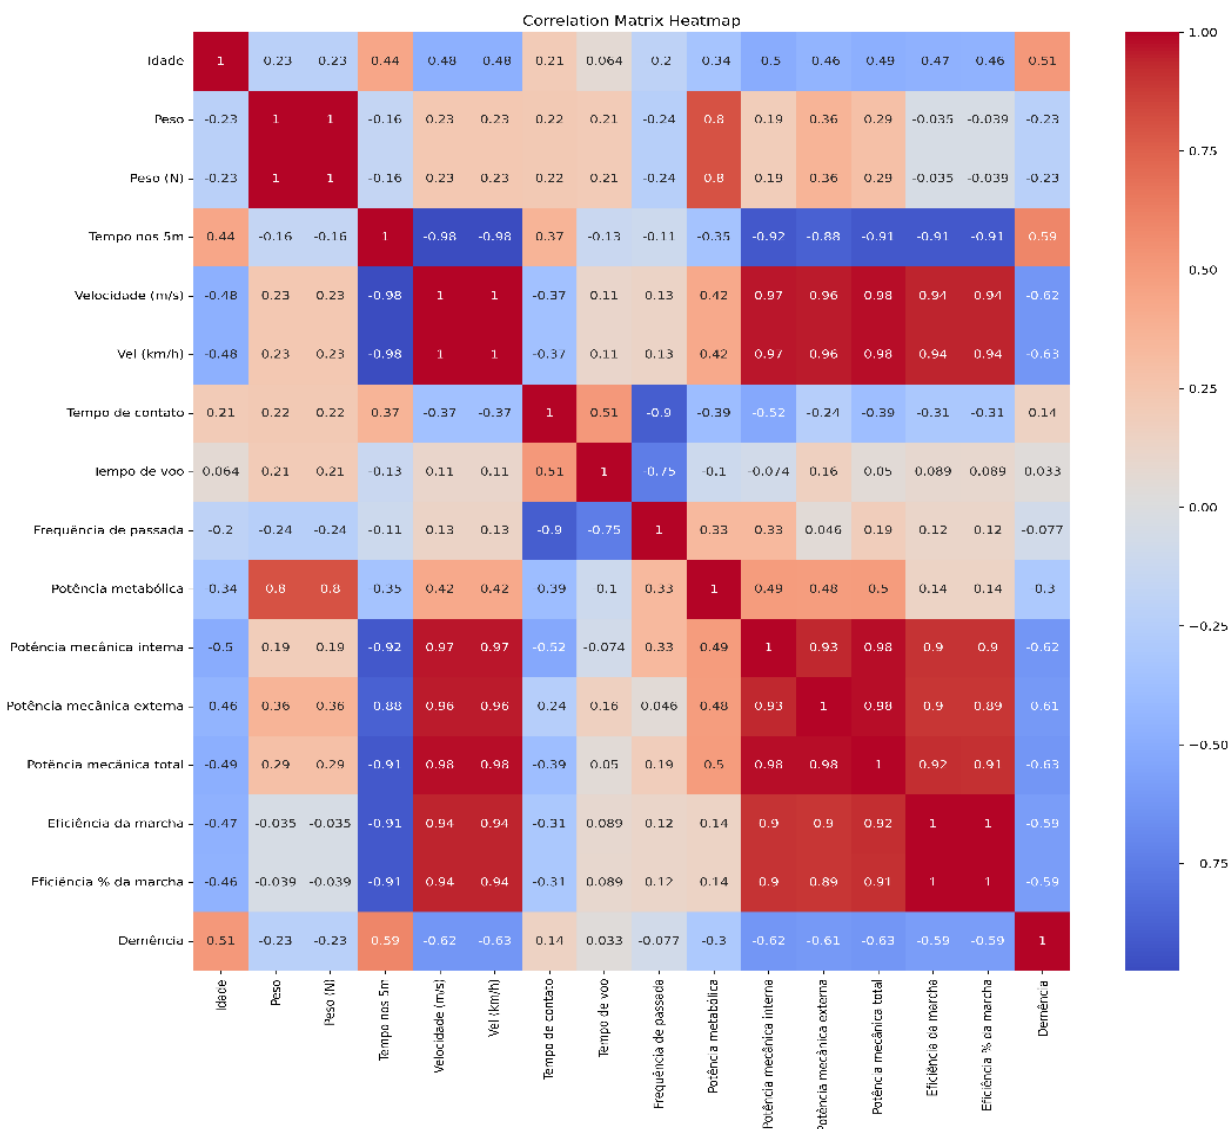


Figura 3 – Matriz de correlação entre as variáveis independentes e a variável-alvo da classificação (demência) para todos os participantes.

4.2. Algoritmos de *machine learning*

A tabela 2 mostra os resultados da aplicação dos nove algoritmos de *machine learning*. Os resultados revelaram bom desempenho global (74,6%) para classificar a demência baseado na idade, no tempo na caminhada em 5 metros, nas potências mecânicas interna e externa e na eficiência da marcha. O melhor algoritmo foi o classificador Ada Boost (83,5%). Além disso, os algoritmos apresentaram precisão (76%) e sensibilidade (72,5), mostrando que respectivamente tiveram desempenhos balanceados para diferenciar verdadeiros positivos em relação e a falsos positivos, e para identificar a proporção de verdadeiros positivos relativamente aos participantes que realmente foram positivos. O escore F-1 mostrou um bom balanço entre a precisão e a sensibilidade das análises, reportando um percentual harmônico (74,9%).

Tabela 2. Métricas de desempenho dos algoritmos de *machine learning* implementados.

Algoritmo	Acurácia (%)	Precisão (%)	Sensibilidade (%)	Escore F-1 (%)	AUC	\bar{x}	VN	FP	FN	VP
<i>Naive Bayes</i>	72,2	77,7	70	73,6	88,7	76,4	6	2	3	7
<i>Regressão Logística</i>	72,2	77,7	70	73,6	91,2	76,9	6	2	3	7
<i>Floresta Randômica</i>	66,6	75	60	66,6	87,5	71,1	6	2	4	6
<i>Classificador de Vetores de Suporte</i>	72,2	77,7	70	73,6	81,2	74,9	6	2	3	7
<i>Classificador K-Nearest Neighbors</i>	77,7	80	80	80	83,7	80,2	6	2	2	8
<i>Árvore de Decisão</i>	72,2	77,7	70	73,6	72,5	73,2	6	2	3	7
<i>Classificador Gradient Boosting</i>	72,2	75,9	72,2	71,9	73,7	73	7	1	4	6
Classificador Ada Boost	83,3	83,9	83,3	83,3	83,7	83,5	7	1	2	8
<i>Classificador Xgboost</i>	77,7	79,7	77,7	78,7	78,5	78,5	7	1	3	7
<i>Métricas gerais (\bar{x})</i>	75,1	76	72,5	74,9	82,2	74,6	NA	NA	NA	NA

Nota – AUC: Área sobre a curva, \bar{x} : média aritmética, VN: verdadeiros negativos, FP: Falsos positivos, FN: falsos negativos, VP: verdadeiros positivos, NA: Não aplicável. **Melhor painel classificatório:** idade, a potência mecânica interna, o tempo na caminhada de 5 metros, a potência mecânica externa, e eficiência da marcha.

A figura 4 a seguir é uma representação gráfica que ilustra a relação entre a taxa de verdadeiros positivos e falsos positivos, duas métricas importantes de avaliação de um modelo de classificação, na qual a Regressão Logística se destacou em relação aos outros algoritmos, estando mais próxima do limite de decisão durante o conjunto de testes de dados (AUC = 0,91). No entanto, a média global da AUC para todos os algoritmos atingiu 82,2%, evidenciando uma alta probabilidade de classificações corretas durante a execução dos algoritmos.

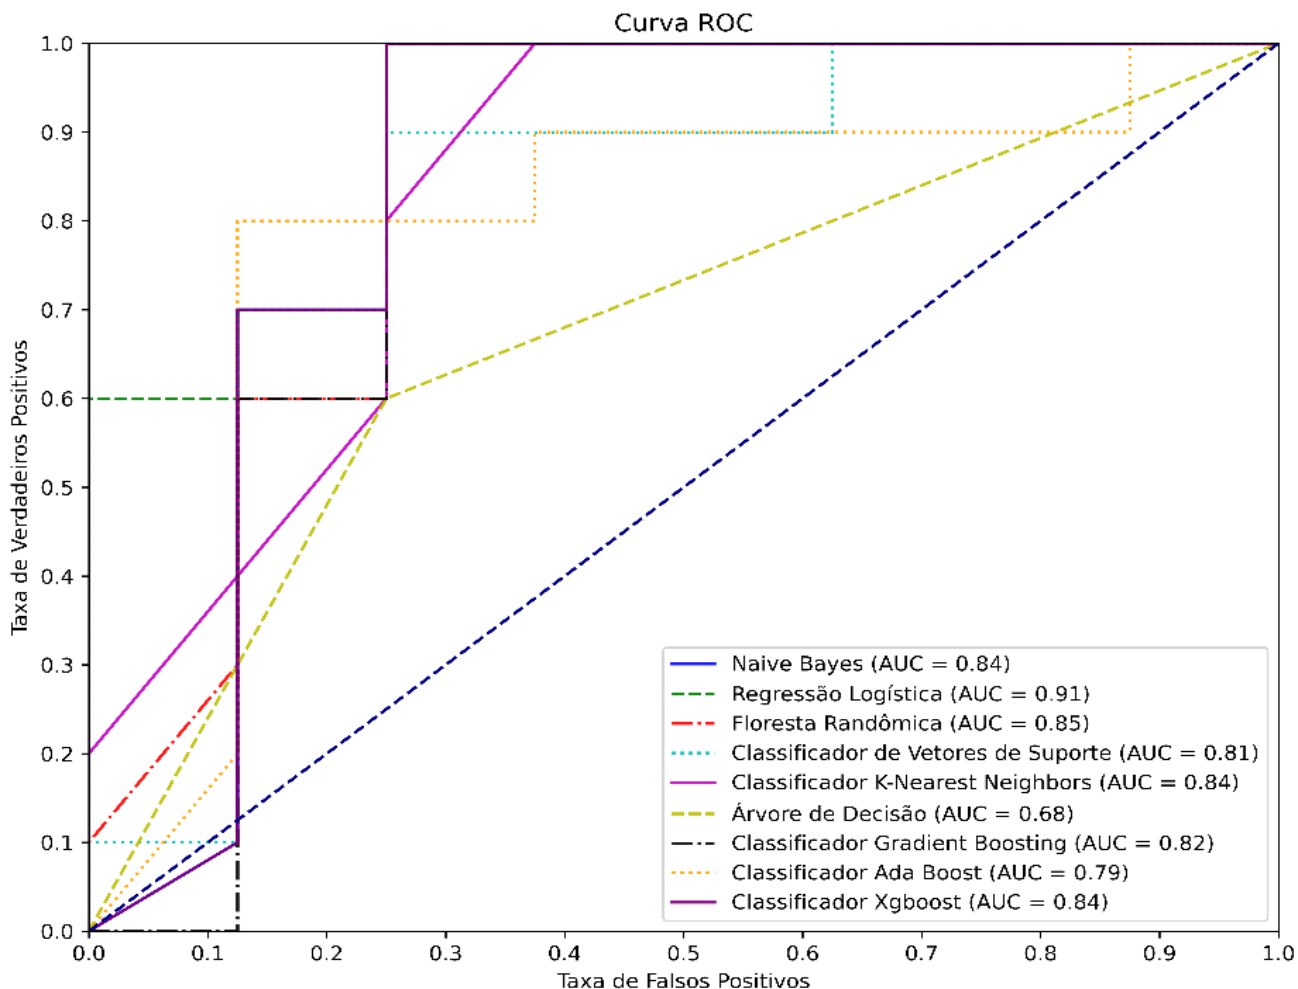


Figura 4 – Área acima da curva ROC para os nove algoritmos de *machine learning* implementados.

4.3. Validação cruzado dos algoritmos

A tabela 3 mostra os resultados da validação cruzada do conjunto de dados usado nas análises, onde foi observada uma acurácia geral de 72% considerando todos os algoritmos. O melhor algoritmo de forma individual foi o classificador de vetores de suporte (acurácia = 80%). Considerando a instabilidade da acurácia ao longo dos subconjuntos do conjunto original de dados, o classificador de vetores de suporte e *Naive Bayes* apresentaram os subconjuntos com melhores acurácias para validação.

Tabela 3. Métricas de desempenho de validação cruzada dos algoritmos de *machine learning* implementados.

<i>Algoritmo</i>	<i>Acurácia (%)</i>	<i>Acurácia (Sub.1)</i>	<i>Acurácia (Sub.2)</i>	<i>Acurácia (Sub.3)</i>	<i>Acurácia (Sub.4)</i>	<i>Acurácia (Sub.5)</i>	<i>DP</i>
<i>Naive Bayes</i>	0.80	0.66	0.83	0.83	0.75	0.90	0.08
<i>Regressão Logística</i>	0.78	0.66	0.83	0.83	0.83	0.72	0.06
<i>Floresta Randômica</i>	0.67	0.58	0.75	0.66	0.75	0.63	0.06
<i>Classificador de Vetores de Suporte</i>	0.80	0.66	0.83	0.83	0.83	0.81	0.06
<i>Classificador K-Nearest Neighbors</i>	0.71	0.75	0.75	0.75	0.75	0.54	0.08
<i>Árvore de Decisão</i>	0.64	0.58	0.83	0.41	0.75	0.63	0.14
<i>Classificador Gradient Boosting</i>	0.69	0.75	0.83	0.58	0.75	0.54	0.11
<i>Classificador Ada Boost</i>	0.71	0.75	0.83	0.66	0.58	0.72	0.08
<i>Classificador Xgboost</i>	0.69	0.66	0.83	0.58	0.75	0.63	0.08
<i>Métricas gerais (\bar{x})</i>	0.72	0.67	0.81	0.68	0.75	0.81	0.05

Nota - Sub: subconjuntos do conjunto de dados usado para testagem dos algoritmos. O melhor modelo está destacado em negrito. DP: desvio padrão da acurácia ao longo dos subconjuntos.

5. DISCUSSÃO

5.1. Discussão da metodologia

O uso da análise de vídeo na marcha de idosos caracteriza-se como uma das ferramentas da metodologia utilizada neste estudo. Segundo Åberg et al. (2021), o método apresentado para extrair as variáveis de marcha do vídeo parece funcionar para uma quantificação confiável e válida. Silva et al., (2020) avaliaram as variáveis de marcha por vídeo, por meio de três diferentes testes (teste de caminhada de 10 metros, teste de levantar e andar cronometrado e teste de caminhada em esteira) e foram capazes de diferenciar indivíduos saudáveis daqueles com comprometimentos cognitivos leves ou Alzheimer.

A escolha da marcha como preditor de demência deveu-se ao facto de a literatura atual indicar que a marcha pode ser uma ferramenta clínica útil para auxiliar no diagnóstico e monitorização da progressão da demência e das doenças neurodegenerativas (Buckley et al., 2019; Verghese et al., 2002). Além disso, declínios e disfunções da marcha estão associados ao comprometimento cognitivo em idosos (Choi et al., 2023; Toots et al., 2019) e podem ter uma marcha mais lenta até 7 anos antes do início clínico da demência, demonstrando assim a relação entre a função cognitiva e motora em idosos (Dumurgier et al., 2017).

Para calcular a estimativa das potencias mecânicas (WINT, WEXT, WTOT) e da potência metabólica (EMET), adotamos os cálculos desenvolvidos por Minetti & Saibene, (1992) e Kram & Taylor (1990). Esses modelos são preditivos, isto é, oferecem previsões com base em variáveis biomecânicas observadas, como a velocidade de deslocamento e nas variáveis

cinemáticas da marcha, ao invés de se basearem em medições diretas dos parâmetros fisiológicos. Embora não capturem diretamente o esforço metabólico ou a mecânica específica do movimento, esses modelos foram confirmados por vários estudos, como para estimativas de potências mecânicas nos estudos de Minetti et al. (1995); Minetti et al. (2000); Luciano et al. (2024), bem como para a estimativa da potência metabólica no estudo de Roberts et al. (1998).

Em nosso estudo, um modelo usando *machine learning* foi usado para classificar o risco de demência associado a um conjunto de variáveis cinemáticas da marcha. Phinyomark et al. (2018), demonstraram que a aplicação de métodos de algoritmos *machine learning* para classificação e agrupamento de dados pode ser uma alternativa mais eficaz. Portanto, este modelo pode ser uma boa opção para pesquisas em biomecânica da marcha. Parque et al. (2023), utilizaram um modelo baseado em parâmetros da marcha para classificar distúrbios cognitivos e sugerem que podem ser uma boa alternativa para distinção dos controles saudáveis em adultos mais velhos.

5.2. Discussão dos Resultados

O objetivo deste estudo foi classificar o risco de Demência com base em variáveis cinemáticas da marcha de idosos, utilizando algoritmos de *machine learning*. A principal conclusão foi que a associação entre as variáveis da marcha é capaz de identificar e classificar o risco de Demência com base na análise da eficiência da marcha de idosos, utilizando algoritmos de *machine learning*.

Na estatística paramétrica e não paramétrica, foram observadas diferenças estatisticamente significativas entre o grupo de idosos institucionalizados (GI) e não institucionalizados (GNI) nas variáveis relacionadas à marcha e desempenho cognitivo. O grupo GNI apresentou superioridade com grandes tamanhos de efeito em variáveis como idade (GI=82,19 ± 7,86/ GNI=71,66 ± 4,78), tempo nos 5 metros (GI=5,59 ± 1,15/ GNI=3,97 ± 0,32), velocidade (m/s) de marcha (GI=0,93 ± 0,20/ GNI=1,26 ± 0,10), potência mecânica interna (GI=19,51 ± 9,20/ GNI=35,79 ± 6,55), potência mecânica externa (GI=10,16 ± 10,10/ GNI=26,67 ± 7,85), potência mecânica total (GI=29,67 ± 18,90/ GNI=62,46 ± 13,57), eficiência da marcha (GI=0,1661 ± 0,0848/ GNI=0,3396 ± 0,0516), assim como no tempo de contato (GI=0,66 ± 0,08/ GNI=0,63 ± 0,05), porém com tamanho de efeito pequeno. Além disso, o grupo GI apresentou menor score no MEEM, com média de 18,53 ± 5,17 pontos, indicando possível comprometimento cognitivo leve (18 a 23 pontos) ou, em alguns casos, comprometimento cognitivo moderado a grave (0 a 17 pontos).

Foi possível identificar as melhores variáveis de marcha associados à demência através da análise da eficiência da marcha, como observado na matriz de correlação (Figura 3), as variáveis da marcha como a potência mecânica interna, externa e total, assim como a velocidade da marcha, eficiência da marcha, idade e o tempo de caminhada demonstraram

diferenças entre os grupos e apresentaram uma correlação com a demência (figura 3), no entanto, apenas um conjunto de cinco variáveis independentes foram utilizados na classificação da demência nos participantes, incluindo idade, potência mecânica interna, tempo de caminhada de 5 metros, potência mecânica externa e o percentual de eficiência da marcha. Isto pode ser observado nos estudos de Chiaramonte & Cioni (2021) e Cedervall et al (2014) onde foi relatado que o com o avanço da demência, é possível observar uma diferença significativa nos parâmetros espaço temporais da marcha, como velocidade, cadência, comprimento da passada, tempo de passada, variabilidade do tempo de passada e comprimento da passada.

Outro fator observado foi em relação a eficiência da marcha, enquanto o grupo GI apresentou valores aproximados de 17% o grupo GNI apresentou valores aproximados de 34%, demonstrando uma grande diferença entre os grupos. No estudo de Mian et al. (2006), onde se comparou potência mecânica e eficiência durante a caminhada em homens jovens e idosos, foi encontrado valores aproximados entre 17 a 25 % na eficiência de marcha dos idosos, sendo valores próximos aos nossos achados. Além disso, Kuan et al. (2021), constatou que mesmo nas fases iniciais a disfunção cognitiva tem algum impacto negativo no equilíbrio e na marcha, pelo que a diferença entre os grupos pode ser explicada por este fator.

Em síntese, nossa pesquisa encontrou uma grande variação na biomecânica da marcha entre idosos institucionalizados (GI) e não institucionalizados (GNI), com o GNI mostrando um desempenho superior em termos de velocidade, potência mecânica (interna, externa e total) e eficiência na marcha. Esta superioridade nos indicadores de marcha, juntamente com as variações no escore de avaliação cognitiva, indica que essas variáveis podem um recurso útil na avaliação do risco de demência.

Os resultados dos algoritmos de *machine learning* mostraram uma precisão global de 74,6% na classificação da demência, com o algoritmo Ada Boost a apresentar o melhor desempenho (83,5%). Os algoritmos mostraram-se eficazes e confiáveis na tarefa de classificação de demências, com 72,5% de casos positivos, precisão (proporção de verdadeiros positivos em relação ao número total de positivos classificados) de 76%, escore F-1 (média harmônica entre precisão e sensibilidade, erros de equilíbrio) de 74,9% e AUC (mede a capacidade do modelo de distinguir entre classes) média de 82,2%. A validação cruzada dos algoritmos revelou uma precisão global de 72%, com o Classificador de Vetores de Suporte a apresentar o melhor desempenho individual (80%), indicando que este modelo respondeu corretamente a 80% das classificações nos diferentes subconjuntos de dados, revelando-se o mais eficaz entre os algoritmos testados. Assim, uma combinação de fatores sendo a idade, a potência mecânica interna, o tempo na caminhada de 5 metros, a potência mecânica externa, e o percentual de eficiência da marcha explicam o bom desempenho dos algoritmos, confirmando que essas variáveis são bons preditores para classificar a demência.

Estudos anteriores, como o de Cabitza et al. (2020), afirmam que desempenhos de 70

a 90% são considerados bons resultados, o que é consistente com nossos achados. Além disso, a análise da marcha como indicador de distúrbios cognitivos foi explorada na pesquisa de J. Park et al. (2023), eles também a utilizaram como parâmetro do estado mental do MEEM, encontrando valores de AUC próximos a 80%, sendo semelhantes aos nossos (82,2%), onde se verificou que a análise da marcha pode distinguir com precisão idosos com distúrbios cognitivos de adultos saudáveis.

A meta-análise desenvolvida por Mc Ardle et al (2017) mostra que as características da marcha associadas à demência são caracterizadas por um ritmo mais lento e maior variabilidade, e que a marcha pode ser usada para diferenciar alguns subtipos de demência, assim como Fritz et al. (2016), também observaram essa distinção de subtipos através de características motoras. Os estudos de Lo & Manor (2023); Byun et al. (2018) e Montero-Odasso et al. (2018), corroboram demonstrando que a velocidade da marcha e a variabilidade da marcha estão associadas à diminuição da função cognitiva e ao aparecimento de demência.

A instabilidade, o controle postural e as alterações motoras estão associados a perturbações cognitivas (Costa et al., 2016), bem como a alterações motoras (Semba et al., 2020), além disso, Doan et al. (2023), descobriram que a redução da massa celular corporal e das funções dos membros inferiores estão ligadas a perturbações cognitivas. Ijmker & Lamoth (2012), observaram que os pacientes com demência têm maior variabilidade da marcha, de modo que essas alterações promovem uma influência negativa na marcha, explicando sua degradação quando associada à demência.

A ativação do córtex pré-frontal é reduzida em indivíduos com deficiências nos domínios cognitivos (Mirelman et al., 2017). Também demonstraram ter uma diminuição no volume de massa do hipocampo (Ezzati et al., 2015), bem como uma maior disfunção do lobo temporal e frontal (Beauchet et al., 2008; X. Guo et al., 2001), pelo que estes elementos fisiológicos estão também relacionados com a deterioração e perda do desempenho da marcha.

Com isso, descobrimos que a marcha não requer apenas o sistema motor, mas também uma integração com o sistema cerebral para alcançar maior controle motor, equilíbrio, coordenação, bem como planejamento e atenção. Em resumo, nosso estudo mostrou que os algoritmos de *machine learning*, particularmente o Ada Boost e o Classificador de Vetores de Suporte, são instrumentos eficientes e confiáveis para identificar o risco de demência em idosos por meio da avaliação da marcha. A combinação de indicadores biomecânicos, como eficiência de movimento e potência mecânica, mostrou-se eficaz na detecção de problemas cognitivos, destacando a eficácia desses algoritmos na classificação de demência.

5.3. Aplicações

O estudo demonstrou que os algoritmos de *machine learning* podem classificar a demência usando variáveis cinemáticas de marcha. Isto pode ser utilizado para uma

identificação precoce e posteriormente ser feita uma intervenção mais eficiente. Considerando que se trata de um método de baixo custo, o sistema nacional de saúde, sistema nacional de apoio social, ONGs e setor privado poderão utilizá-lo no rastreio de idosos e identificar aqueles com maior risco de demência e facilitar a comunicação entre médicos e cuidadores para monitorizar continuamente o estado cognitivo dos doentes, proporcionando uma personalização de cuidados mais específicos e personalizados nos lares. Além disso, poderia ajudar a planejar políticas públicas de prevenção e tratamento precoce e criar campanhas de sensibilização e promover cuidados específicos e exercício físico para estes idosos.

Para implementar tal sistema em lares, clínicas ou centros de saúde, seria necessário incluir um especialista em saúde, com a tarefa de realizar avaliações regulares dos idosos e registrar a sua marcha, obtendo assim as suas variáveis. Além disso, seria necessário aplicar o Mini Exame do Estado Mental (MEEM) para avaliar a condição cognitiva. Esses dados seriam examinados por algoritmos de *machine learning*, onde deveria ser previamente desenvolvido um sistema para colocar esses dados de forma simples e intuitiva, como um prontuário eletrônico, onde a *machine learning* já estaria treinada e automatizada apenas para receber esses dados e gerar relatórios que seriam direcionados aos profissionais de saúde. Assim, poderíamos realizar avaliações regulares, permitindo um acompanhamento constante e intervenções rápidas quando necessário.

5.4.Limitações

O presente estudo apresentou algumas limitações, uma amostra maior e mais robusta de participantes aumentaria as características a serem analisadas e melhoraria a precisão das estimativas. Outro fator foi que a amostra foi composta maioritariamente por mulheres (69,57%), o que é outro fator limitante para uma generalização dos resultados. Estudos futuros devem procurar ter uma amostra mais equilibrada em termos de sexos, e devem testar o efeito sexo, para observar se o modelo de classificação será dependente ou não do sexo.

Além disso, pesquisas futuras devem se concentrar na coleta de conjuntos maiores de características, tanto em termos de história de outras patologias, hábitos alimentares, estilo de vida, componentes sociodemográficos, bioquímicos e genéticos dos participantes.

Como resultado, amostras maiores serão capazes de revelar características com correlações mais elevadas, o que facilita a aprendizagem e pode melhorar o desempenho dos modelos implementados. Além disso, a validação independente dos resultados deste estudo em outras populações ao nível da etnia e região do mundo pode trazer melhores resultados, uma vez que os idosos diferem em termos de fatores geográficos, culturais, socioeconômicos e de estilo de vida, bem como aspetos como saúde, bem-estar e expectativa de vida, portanto, a realização deste estudo em diferentes regiões seria de grande valia.

6. CONCLUSÕES

Este estudo investigou a viabilidade de identificar e classificar o risco de Demência com base na análise das variáveis cinemáticas relacionadas com a marcha de idosos, utilizando algoritmos de *machine learning*. A metodologia utilizada, baseada na análise de vídeo, demonstrou que o aumento do tempo de caminhada, a redução das potências mecânicas interna e externa, bem como a eficiência da marcha, apresentaram correlação com a demência, possibilitando a classificação do risco de demência.

Os modelos algorítmicos desenvolvidos, particularmente o Classificador Ada Boost e o Classificador de Vetores de Suporte, demonstraram ser muito bons na classificação de distúrbios cognitivos, sugerindo que a análise da marcha, combinada com algoritmos de *machine learning*, é um método confiável e eficaz para classificar a demência. Relatando, assim, uma perspectiva promissora para a detecção precoce e monitoramento de distúrbios cognitivos em idosos para intervenções precoces e melhoria da qualidade de vida dos idosos.

7. REFERÊNCIAS BIBLIOGRÁFICAS

Åberg, A. C., Olsson, F., Åhman, H. B., Tarassova, O., Arndt, A., Giedraitis, V., Berglund, L., & Halvorsen, K. (2021). Extraction of gait parameters from marker-free video recordings of Timed Up-and-Go tests: Validity, inter- and intra-rater reliability. *Gait & Posture*, *90*, 489–495. <https://doi.org/10.1016/j.gaitpost.2021.08.004>

Afonso, M. B. de P. (2022, março 17). A Demência no idoso. *A Demência no idoso*. A Demência no idoso. <https://estudogeral.uc.pt/handle/10316/102465>

Ahn, K., Lee, S.-J., & Mook-Jung, I. (2022). White matter-associated microglia: New players in brain aging and neurodegenerative diseases. *Ageing Research Reviews*, *75*, 101574. <https://doi.org/10.1016/j.arr.2022.101574>

Alexander, R. M. (2003). *Principles of Animal Locomotion*. Princeton University Press.

Alves, S., Duarte, N., & Gomes, B. (2024). Forecasted Dementia Prevalence in Portugal (2020-2080). *Journal of Geriatric Psychiatry and Neurology*, 08919887241237220. <https://doi.org/10.1177/08919887241237220>

Alzheimer's Disease International. (2023). *World Alzheimer Report 2023: Reducing Dementia Risk: Never too early, never too late*. <https://www.alzint.org/resource/world-alzheimer-report-2023/>

Araújo, C. L. de O., & Nicoli, J. S. (2010). Uma revisão bibliográfica das principais demências que acometem a população brasileira. *Revista Kairós-Gerontologia*, *13*(1). <https://doi.org/10.23925/2176-901X.2010v13i1p%p>

Ball, L. J., & Birge, S. J. (2002). Prevention of brain aging and dementia. *Clinics in Geriatric Medicine*, *18*(3), 485–503. [https://doi.org/10.1016/s0749-0690\(02\)00027-7](https://doi.org/10.1016/s0749-0690(02)00027-7)

Barbosa, P. J. R. (2012). *Otimização de locomoção bípede* [masterThesis]. <https://repositorium.sdum.uminho.pt/handle/1822/23405>

- Beata, B.-K., Wojciech, J., Johannes, K., Piotr, L., & Barbara, M. (2023). Alzheimer's Disease-Biochemical and Psychological Background for Diagnosis and Treatment. *International Journal of Molecular Sciences*, 24(2), 1059. <https://doi.org/10.3390/ijms24021059>
- Beauchet, O., Allali, G., Berrut, G., Hommet, C., Dubost, V., & Assal, F. (2008). Gait analysis in demented subjects: Interests and perspectives. *Neuropsychiatric Disease and Treatment*, 4(1), 155–160.
- Beauchet, O., Annweiler, C., Callisaya, M. L., De Cock, A.-M., Helbostad, J. L., Kressig, R. W., Srikanth, V., Steinmetz, J.-P., Blumen, H. M., Verghese, J., & Allali, G. (2016). Poor Gait Performance and Prediction of Dementia: Results From a Meta-Analysis. *Journal of the American Medical Directors Association*, 17(6), 482–490. <https://doi.org/10.1016/j.jamda.2015.12.092>
- Beudart, C., Rolland, Y., Cruz-Jentoft, A. J., Bauer, J. M., Sieber, C., Cooper, C., Al-Daghri, N., Araujo de Carvalho, I., Bautmans, I., Bernabei, R., Bruyère, O., Cesari, M., Cherubini, A., Dawson-Hughes, B., Kanis, J. A., Kaufman, J.-M., Landi, F., Maggi, S., McCloskey, E., ... Fielding, R. A. (2019). Assessment of Muscle Function and Physical Performance in Daily Clinical Practice. *Calcified Tissue International*, 105(1), 1–14. <https://doi.org/10.1007/s00223-019-00545-w>
- Beck Jepsen, D., Robinson, K., Ogliari, G., Montero-Odasso, M., Kamkar, N., Ryg, J., Freiburger, E., & Masud, T. (2022). Predicting falls in older adults: An umbrella review of instruments assessing gait, balance, and functional mobility. *BMC Geriatrics*, 22(1), 615. <https://doi.org/10.1186/s12877-022-03271-5>
- Bettio, L. E. B., Rajendran, L., & Gil-Mohapel, J. (2017). The effects of aging in the hippocampus and cognitive decline. *Neuroscience and Biobehavioral Reviews*, 79, 66–86. <https://doi.org/10.1016/j.neubiorev.2017.04.030>
- Biancardi, C., Bona, R., & Hausheer, L. (2020). LOCOMOCIÓN HUMANA: MODELOS Y VARIABLES BIOMECÁNICAS HUMAN LOCOMOTION: MODELS AND BIOMECHANICAL VARIABLES. *Pensar en Movimiento Revista de Ciencias del Ejercicio y la Salud*, 18, e40315. <https://doi.org/10.15517/pensarmov.v18i2.41360>
- Borges-Machado, F., Silva, N., Farinatti, P., Poton, R., Ribeiro, Ó., & Carvalho, J. (2021). Effectiveness of Multicomponent Exercise Interventions in Older Adults With Dementia: A Meta-Analysis. *The Gerontologist*, 61(8), e449–e462. <https://doi.org/10.1093/geront/gnaa091>
- Borgo, C. M. (2021). Os efeitos do exercício físico na prevenção de quedas em idosos com doença de Alzheimer: Revisão Integrativa. <http://200.150.122.211:8080/jspui/handle/23102004/320>
- Bradley, A. P. (1997). The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognition*, 30(7), 1145–1159. [https://doi.org/10.1016/S0031-3203\(96\)00142-2](https://doi.org/10.1016/S0031-3203(96)00142-2)
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Bridenbaugh, S. A., & Kressig, R. W. (2014). Quantitative gait disturbances in older adults with cognitive impairments. *Current Pharmaceutical Design*, 20(19), 3165–3172. <https://doi.org/10.2174/13816128113196660688>
- Buckley, C., Alcock, L., McArdle, R., Rehman, R. Z. U., Del Din, S., Mazzà, C., Yarnall, A. J., & Rochester, L. (2019). The Role of Movement Analysis in Diagnosing and Monitoring

Neurodegenerative Conditions: Insights from Gait and Postural Control. *Brain Sciences*, 9(2), 34. <https://doi.org/10.3390/brainsci9020034>

Byun, S., Han, J. W., Kim, T. H., Kim, K., Kim, T. H., Park, J. Y., Suh, S. W., Seo, J. Y., So, Y., Lee, K. H., Lee, J. R., Jeong, H., Jeong, H.-G., Han, K., Hong, J. W., & Kim, K. W. (2018). Gait Variability Can Predict the Risk of Cognitive Decline in Cognitively Normal Older People. *Dementia and Geriatric Cognitive Disorders*, 45(5–6), 251–261. <https://doi.org/10.1159/000489927>

Cabitza, F., Campagner, A., Del Zotti, F., Verona, N., Ravizza, A., & Sternini, F. (2020). *All you need is higher accuracy? On the quest for minimum acceptable accuracy for Medical Artificial Intelligence.*

Cai, J., Luo, J., Wang, S., & Yang, S. (2018). Feature selection in machine learning: A new perspective. *Neurocomputing*, 300, 70–79. <https://doi.org/10.1016/j.neucom.2017.11.077>

Carvalho, A. R. D., Andrade, A., & Peyré-Tartaruga, L. A. (2015). Possíveis alterações no mecanismo minimizador de energia da caminhada em decorrência da dor lombar crônica - revisão de literatura. *Revista Brasileira de Reumatologia*, 55(1), 55–61. <https://doi.org/10.1016/j.rbr.2014.01.013>

Cavagna, G. A., & Kaneko, M. (1977). Mechanical work and efficiency in level walking and running. *The Journal of Physiology*, 268(2), 467–481. <https://doi.org/10.1113/jphysiol.1977.sp011866>

Cavagna, G. A., & Margaria, R. (1966). Mechanics of walking. *Journal of Applied Physiology*, 21(1), 271–278. <https://doi.org/10.1152/jappl.1966.21.1.271>

Cavagna, G. A., Saibene, F. P., & Margaria, R. (1963). External work in walking. *Journal of Applied Physiology*, 18, 1–9. <https://doi.org/10.1152/jappl.1963.18.1.1>

Cavalcanti, D. B. A. (2023). Correlações entre função cognitiva, independência funcional e risco de queda em idosos com demência de Alzheimer. *Fisioterapia Brasil*, 24(4), Artigo 4. <https://doi.org/10.33233/fb.v24i4.5357>

Cedervall, Y., Halvorsen, K., & Åberg, A. C. (2014). A longitudinal study of gait function and characteristics of gait disturbance in individuals with Alzheimer's disease. *Gait & Posture*, 39(4), 1022–1027. <https://doi.org/10.1016/j.gaitpost.2013.12.026>

Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., & Lopez, A. (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 408, 189–215. <https://doi.org/10.1016/j.neucom.2019.10.118>

Chen, K. Y., Acra, S. A., Donahue, C. L., Sun, M., & Buchowski, M. S. (2004). Efficiency of Walking and Stepping: Relationship to Body Fatness. *Obesity Research*, 12(6), 982–989. <https://doi.org/10.1038/oby.2004.120>

Chiaromonte, R., & Cioni, M. (2021). Critical spatiotemporal gait parameters for individuals with dementia: A systematic review and meta-analysis. *Hong Kong Physiotherapy Journal: Official Publication of the Hong Kong Physiotherapy Association Limited = Wu Li Chih Liao*, 41(1), 1–14. <https://doi.org/10.1142/S101370252130001X>

Choi, J.-Y., Ha, S.-W., Jeong, D.-E., Lee, J., Kim, D., Min, J.-Y., & Min, K.-B. (2023). Association Between the Loss of Gait Harmony and Cognitive Impairment: Cross-Sectional Study. *JMIR Public Health and Surveillance*, 9, e46264. <https://doi.org/10.2196/46264>

Cohen, J. (2013). *Statistical Power Analysis for the Behavioral Sciences*. Academic Press.

Collyer, T. A., Murray, A. M., Woods, R. L., Storey, E., Chong, T. T.-J., Ryan, J., Orchard, S. G., Brodtmann, A., Srikanth, V. K., Shah, R. C., & Callisaya, M. L. (2022). Association of Dual Decline in Cognition and Gait Speed With Risk of Dementia in Older Adults. *JAMA Network Open*, 5(5), e2214647. <https://doi.org/10.1001/jamanetworkopen.2022.14647>

Correia, C. S. A. (2022). *Análise de EMG no domínio da frequência em indivíduos com marcha hemiparética pós-AVC* [masterThesis]. <https://repositorio.ul.pt/handle/10451/55956>

Costa, L., Gago, M. F., Yelshyna, D., Ferreira, J., David Silva, H., Rocha, L., Sousa, N., & Bicho, E. (2016). Application of Machine Learning in Postural Control Kinematics for the Diagnosis of Alzheimer's Disease. *Computational Intelligence and Neuroscience*, 2016, 3891253. <https://doi.org/10.1155/2016/3891253>

Cruz-Jentoft, A. J., Bahat, G., Bauer, J., Boirie, Y., Bruyère, O., Cederholm, T., Cooper, C., Landi, F., Rolland, Y., Sayer, A. A., Schneider, S. M., Sieber, C. C., Topinkova, E., Vandewoude, M., Visser, M., & Zamboni, M. (2019). Sarcopenia: Revised European consensus on definition and diagnosis. *Age and Ageing*, 48(1), 16–31. <https://doi.org/10.1093/ageing/afy169>

Cunningham, E., McGuinness, B., Herron, B., & Passmore, A. (2015). Dementia. *The Ulster Medical Journal*, 84(2), 79–87.

Deschamps, T. (2018). Is Psychiatry Ready to Move? *Psychiatry Investigation*, 15(1), 3–5. <https://doi.org/10.4306/pi.2018.15.1.3>

Doan, D. N. T., Kim, K., Ku, B., Lee, K. H., & Kim, J. U. (2023). Reduced body cell mass and functions in lower extremities are associated with mild cognitive impairment and Alzheimer's dementia. *Scientific Reports*, 13(1), 13389. <https://doi.org/10.1038/s41598-023-39110-9>

Doi, T., Makizako, H., Tsutsumimoto, K., Hotta, R., Nakakubo, S., Makino, K., Suzuki, T., & Shimada, H. (2018). Combined effects of mild cognitive impairment and slow gait on risk of dementia. *Experimental Gerontology*, 110, 146–150. <https://doi.org/10.1016/j.exger.2018.06.002>

Dumurgier, J., Artaud, F., Touraine, C., Rouaud, O., Tavernier, B., Dufouil, C., Singh-Manoux, A., Tzourio, C., & Elbaz, A. (2017). Gait Speed and Decline in Gait Speed as Predictors of Incident Dementia. *The Journals of Gerontology: Series A*, 72(5), 655–661. <https://doi.org/10.1093/gerona/glw110>

Dunsky, A. (2019). The Effect of Balance and Coordination Exercises on Quality of Life in Older Adults: A Mini-Review. *Frontiers in Aging Neuroscience*, 11. <https://doi.org/10.3389/fnagi.2019.00318>

Ezzati, A., Katz, M. J., Lipton, M. L., Lipton, R. B., & Verghese, J. (2015). The association of brain structure with gait velocity in older adults: A quantitative volumetric analysis of brain MRI. *Neuroradiology*, 57(8), 851–861. <https://doi.org/10.1007/s00234-015-1536-2>

Faieta, J. M., Devos, H., Vaduvathiryan, P., York, M. K., Erickson, K. I., Hirsch, M. A., Downer, B. G., van Wegen, E. E. H., Wong, D. C., Philippou, E., Negm, A., Ahmadnezhad, P., Krishnan, S., Kahya, M., Sood, P., & Heyn, P. C. (2021). Exercise interventions for older adults with Alzheimer's disease: A systematic review and meta-analysis protocol. *Systematic Reviews*, 10(1), 6. <https://doi.org/10.1186/s13643-020-01555-8>

Farris, D. J., & Sawicki, G. S. (2012). The mechanics and energetics of human walking and running: A joint level perspective. *Journal of the Royal Society, Interface*, 9(66), 110–118.

<https://doi.org/10.1098/rsif.2011.0182>

Ferguson, C. J. (2009). An effect size primer: A guide for clinicians and researchers. *Professional Psychology: Research and Practice*, 40(5), 532–538. <https://doi.org/10.1037/a0015808>

Fritz, N. E., Kegelmeyer, D. A., Kloos, A. D., Linder, S., Park, A., Kataki, M., Adeli, A., Agrawal, P., Scharre, D. W., & Kostyk, S. K. (2016). Motor performance differentiates individuals with Lewy body dementia, Parkinson's and Alzheimer's disease. *Gait & Posture*, 50, 1–7. <https://doi.org/10.1016/j.gaitpost.2016.08.009>

Galdino, M. V. (2020). *Modelos probabilísticos e não probabilísticos de classificação binária para pacientes com ou sem demência como auxílio na prática clínica em geriatria*. <http://hdl.handle.net/11449/192418>

Gallucci, J., Tamelini, M. G., & Forlenza, O. V. (2005). Diagnóstico diferencial das demências. *Archives of Clinical Psychiatry (São Paulo)*, 32, 119–130. <https://doi.org/10.1590/S0101-60832005000300004>

Griffiths, J., & Grant, S. G. N. (2023). Synapse pathology in Alzheimer's disease. *Seminars in Cell & Developmental Biology*, 139, 13–23. <https://doi.org/10.1016/j.semcdb.2022.05.028>

Grimmer, M., Riener, R., Walsh, C. J., & Seyfarth, A. (2019). Mobility related physical and functional losses due to aging and disease—A motivation for lower limb exoskeletons. *Journal of NeuroEngineering and Rehabilitation*, 16(1), 2. <https://doi.org/10.1186/s12984-018-0458-8>

Guerreiro, M., Silva, A. A., Botelho, M., Leitão, O., Castro-Caldas, A., García, C., Silva, Á., Botelho, M., Botelho, A., Guerreiro, M., Botelho, M., Robusto-Leitao, O., Castro, A. A. J. F., & Garcia, A. S. (1994). *Adaptação à população portuguesa da tradução do Mini Mental State Examination (MMSE)*. <https://www.semanticscholar.org/paper/Adapta%C3%A7%C3%A3o-%C3%A0-popula%C3%A7%C3%A3o-portuguesa-da-tradu%C3%A7%C3%A3o-do-Guerreiro-Silva/bd5ff137461873bea32fdd1b0412daa43810fdb0>

Guo, X., Steen, B., Matousek, M., Andreasson, L. A., Larsson, L., Palsson, S., Sundh, V., & Skoog, I. (2001). A population-based study on brain atrophy and motor performance in elderly women. *The Journals of Gerontology. Series A, Biological Sciences and Medical Sciences*, 56(10), M633-637. <https://doi.org/10.1093/gerona/56.10.m633>

Guo, Y., Yang, J., Liu, Y., Chen, X., & Yang, G.-Z. (2022). Detection and assessment of Parkinson's disease based on gait analysis: A survey. *Frontiers in Aging Neuroscience*, 14. <https://doi.org/10.3389/fnagi.2022.916971>

Hao, J., & Ho, T. K. (2019). Machine Learning Made Easy: A Review of Scikit-learn Package in Python Programming Language. *Journal of Educational and Behavioral Statistics*, 44(3), 348–361. <https://doi.org/10.3102/1076998619832248>

Haslwanter, T. (2016). *An Introduction to Statistics with Python: With Applications in the Life Sciences*. Springer International Publishing.

Hicks, S. A., Strümke, I., Thambawita, V., Hammou, M., Riegler, M. A., Halvorsen, P., & Parasa, S. (2022). On evaluation metrics for medical applications of artificial intelligence. *Scientific Reports*, 12(1), 5979. <https://doi.org/10.1038/s41598-022-09954-8>

Huang, X., Zhao, X., Li, B., Cai, Y., Zhang, S., Wan, Q., & Yu, F. (2022). Comparative efficacy of various exercise interventions on cognitive function in patients with mild cognitive impairment or dementia: A systematic review and network meta-analysis. *Journal of Sport and Health Science*, 11(2), 212–223. <https://doi.org/10.1016/j.jshs.2021.05.003>

Ibrahim, S., Nazir, S., & Velastin, S. A. (2021). Feature Selection Using Correlation Analysis and Principal Component Analysis for Accurate Breast Cancer Diagnosis. *Journal of Imaging*, 7(11), Artigo 11. <https://doi.org/10.3390/jimaging7110225>

Ijmker, T., & Lamoth, C. J. C. (2012). Gait and cognition: The relationship between gait stability and variability with executive function in persons with and without dementia. *Gait & Posture*, 35(1), 126–130. <https://doi.org/10.1016/j.gaitpost.2011.08.022>

Intlekofer, K. A., & Cotman, C. W. (2013). Exercise counteracts declining hippocampal function in aging and Alzheimer's disease. *Neurobiology of Disease*, 57, 47–55. <https://doi.org/10.1016/j.nbd.2012.06.011>

Izzo, T., Higuti, A., Campos, D., Ferreira, D., Barbosa, S., & Ansai, J. (2022). LONGITUDINAL ANALYSIS OF FUNCTIONAL AND CLINICAL FACTORS AND FALLS IN INSTITUTIONALIZED OLDER PEOPLE WITH DEMENTIA. *Movimenta (ISSN 1984-4298)*, 15, 1–12. <https://doi.org/10.31668/movimenta.v15i2.13069>

Jia, L., Du, Y., Chu, L., Zhang, Z., Li, F., Lyu, D., Li, Y., Zhu, M., Jiao, H., Song, Y., Shi, Y., Zhang, H., Gong, M., Wei, C., Tang, Y., Fang, B., Guo, D., Wang, F., Zhou, A., ... Qiu, Q. (2020). Prevalence, risk factors, and management of dementia and mild cognitive impairment in adults aged 60 years or older in China: A cross-sectional study. *The Lancet Public Health*, 5(12), e661–e671. [https://doi.org/10.1016/S2468-2667\(20\)30185-7](https://doi.org/10.1016/S2468-2667(20)30185-7)

Kaczmarczyk, K., & Miałkowska, K. (2022). Backtesting comparison of machine learning algorithms with different random seed. *Procedia Computer Science*, 207. <https://doi.org/10.1016/j.procs.2022.09.248>

Kram, R., & Taylor, C. R. (1990). Energetics of running: A new perspective. *Nature*, 346(6281), 265–267. <https://doi.org/10.1038/346265a0>

Kuan, Y.-C., Huang, L.-K., Wang, Y.-H., Hu, C.-J., Tseng, I.-J., Chen, H.-C., & Lin, L.-F. (2021). Balance and gait performance in older adults with early-stage cognitive impairment. *European Journal of Physical and Rehabilitation Medicine*, 57(4), 560–567. <https://doi.org/10.23736/S1973-9087.20.06550-8>

Lara, E., Koyanagi, A., Olaya, B., Lobo, A., Miret, M., Tyrovolas, S., Ayuso-Mateos, J. L., & Haro, J. M. (2016). Mild cognitive impairment in a Spanish representative sample: Prevalence and associated factors. *International Journal of Geriatric Psychiatry*, 31(8), 858–867. <https://doi.org/10.1002/gps.4398>

Lee, C. R., & Farley, C. T. (1998). Determinants of the center of mass trajectory in human walking and running. *Journal of Experimental Biology*, 201(21), 2935–2944. <https://doi.org/10.1242/jeb.201.21.2935>

Livingston, G., Huntley, J., Sommerlad, A., Ames, D., Ballard, C., Banerjee, S., Brayne, C., Burns, A., Cohen-Mansfield, J., Cooper, C., Costafreda, S. G., Dias, A., Fox, N., Gitlin, L. N., Howard, R., Kales, H. C., Kivimäki, M., Larson, E. B., Ogunniyi, A., ... Mukadam, N. (2020). Dementia prevention, intervention, and care: 2020 report of the Lancet Commission. *Lancet (London, England)*, 396(10248), 413–446. [https://doi.org/10.1016/S0140-6736\(20\)30367-6](https://doi.org/10.1016/S0140-6736(20)30367-6)

Lo, O.-Y., & Manor, B. (2023). Measuring Gait to Monitor Cognitive Function in Older Adults: An Important Step in the Right Direction. *Neurology*, 101(1), 10–11. <https://doi.org/10.1212/WNL.0000000000207528>

Loupa, A., Mesuras, S., Santos, V., Silva, S., Parreira, D., & Ribeiro, A. (2020). *Gait*

biomechanics. 9, 136–140. <https://doi.org/10.36957/jai.2182-696X.v9i1-9>

Luciano, F., Minetti, A., & Pavei, G. (2023). Metabolic cost and mechanical work of walking in a virtual reality emulator. *European Journal of Applied Physiology*, 124, 1–10. <https://doi.org/10.1007/s00421-023-05306-0>

Luciano, F., Ruggiero, L., Minetti, A. E., & Pavei, G. (2024). The work to swing limbs in humans versus chimpanzees and its relation to the metabolic cost of walking. *Scientific Reports*, 14, 8970. <https://doi.org/10.1038/s41598-024-59171-8>

Luvizutto, G. J., & Souza, L. A. P. S. de. (2020). *Avaliação Neurológica Funcional*. Editora Appris.

Maas, S., Festen, D. A. M., Hilgenkamp, T. I. M., & Oppewal, A. (2020). The association between medication use and gait in adults with intellectual disabilities. *Journal of Intellectual Disability Research*, 64(10), 793–803. <https://doi.org/10.1111/jir.12773>

Magalhães, J. P., Stevens, M., & Thornton, D. (2017). The Business of Anti-Aging Science. *Trends in Biotechnology*, 35(11), 1062–1073. <https://doi.org/10.1016/j.tibtech.2017.07.004>

Manly, J. J., Jones, R. N., Langa, K. M., Ryan, L. H., Levine, D. A., McCammon, R., Heeringa, S. G., & Weir, D. (2022). Estimating the Prevalence of Dementia and Mild Cognitive Impairment in the US: The 2016 Health and Retirement Study Harmonized Cognitive Assessment Protocol Project. *JAMA Neurology*, 79(12), 1242–1249. <https://doi.org/10.1001/jamaneurol.2022.3543>

Mc Ardle, R. ona, Galna, B., Donaghy, P., Thomas, A., & Rochester, L. (2019). Do Alzheimer's and Lewy body disease have discrete pathological signatures of gait? *Alzheimer's & dementia : the journal of the Alzheimer's Association*, 15(10). <https://doi.org/10.1016/j.jalz.2019.06.4953>

Mc Ardle, R., Del Din, S., Galna, B., Thomas, A., & Rochester, L. (2020). Differentiating dementia disease subtypes with gait analysis: Feasibility of wearable sensors? *Gait & Posture*, 76, 372–376. <https://doi.org/10.1016/j.gaitpost.2019.12.028>

Mc Ardle, R., Morris, R., Wilson, J., Galna, B., Thomas, A. J., & Rochester, L. (2017). What Can Quantitative Gait Analysis Tell Us about Dementia and Its Subtypes? A Structured Review. *Journal of Alzheimer's Disease: JAD*, 60(4), 1295–1312. <https://doi.org/10.3233/JAD-170541>
Mckinney, W. (2011). pandas: A Foundational Python Library for Data Analysis and Statistics. *Python High Performance Science Computer*.

Mian, O. S., Thom, J. M., Ardigò, L. P., Narici, M. V., & Minetti, A. E. (2006). Metabolic cost, mechanical work, and efficiency during walking in young and older men. *Acta Physiologica (Oxford, England)*, 186(2), 127–139. <https://doi.org/10.1111/j.1748-1716.2006.01522.x>

Minetti, A. E., Ardigo, L. P., Saibene, F., Ferrero, S., & Sartorio, A. (2000). Mechanical and metabolic profile of locomotion in adults with childhood-onset GH deficiency. *European Journal of Endocrinology*, 142(1), 35–41. <https://doi.org/10.1530/eje.0.1420035>

Minetti, A. E., Capelli, C., Zamparo, P., di Prampero, P. E., & Saibene, F. (1995). Effects of stride frequency on mechanical power and energy expenditure of walking. *Medicine and Science in Sports and Exercise*, 27(8), 1194–1202.

Minetti, A. E., & Saibene, F. (1992). Mechanical work rate minimization and freely chosen stride frequency of human walking: A mathematical model. *The Journal of Experimental Biology*, 170, 19–34. <https://doi.org/10.1242/jeb.170.1.19>

Mirelman, A., Maidan, I., Bernad-Elazari, H., Shustack, S., Giladi, N., & Hausdorff, J. M. (2017).

Effects of aging on prefrontal brain activation during challenging walking conditions. *Brain and Cognition*, 115, 41–46. <https://doi.org/10.1016/j.bandc.2017.04.002>

Montero-Odasso, M. M., Sarquis-Adamson, Y., Speechley, M., Borrie, M. J., Hachinski, V. C., Wells, J., Riccio, P. M., Schapira, M., Sejdic, E., Camicioli, R. M., Bartha, R., McIlroy, W. E., & Muir-Hunter, S. (2017). Association of Dual-Task Gait With Incident Dementia in Mild Cognitive Impairment. *JAMA Neurology*, 74(7), 857–865. <https://doi.org/10.1001/jamaneurol.2017.0643>

Montero-Odasso, M., Speechley, M., Muir-Hunter, S. W., Sarquis-Adamson, Y., Sposato, L. A., Hachinski, V., Borrie, M., Wells, J., Black, A., Sejdić, E., Bherer, L., Chertkow, H., & Canadian Gait and Cognition Network. (2018). Motor and Cognitive Trajectories Before Dementia: Results from Gait and Brain Study. *Journal of the American Geriatrics Society*, 66(9), 1676–1683. <https://doi.org/10.1111/jgs.15341>

Murman, D. L. (2015). The Impact of Age on Cognition. *Seminars in Hearing*, 36(3), 111–121. <https://doi.org/10.1055/s-0035-1555115>

Naive Bayes Classifier—An overview | ScienceDirect Topics. (2023). <https://www.sciencedirect.com/topics/engineering/naive-bayes-classifier>

Nakanishi, M., Pereira, S. M., Block, L. V. den, Parker, D., Harrison-Dening, K., Giulio, P. D., Schmitten, J. I. der, Larkin, P. J., Mimica, N., Sudore, R. L., Holmerová, I., Korfage, I. J., & Steen, J. T. van der. (2024). Future policy and research for advance care planning in dementia: Consensus recommendations from an international Delphi panel of the European Association for Palliative Care. *The Lancet Healthy Longevity*, 5(5), e370–e378. [https://doi.org/10.1016/S2666-7568\(24\)00043-6](https://doi.org/10.1016/S2666-7568(24)00043-6)

Natekin, A., & Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in Neurorobotics*, 7, 21. <https://doi.org/10.3389/fnbot.2013.00021>

Nichols, E., Steinmetz, J. D., Vollset, S. E., Fukutaki, K., Chalek, J., Abd-Allah, F., Abdoli, A., Abualhasan, A., Abu-Gharbieh, E., Akram, T. T., Hamad, H. A., Alahdab, F., Alanezi, F. M., Alipour, V., Almustanyir, S., Amu, H., Ansari, I., Arabloo, J., Ashraf, T., ... Vos, T. (2022). Estimation of the global prevalence of dementia in 2019 and forecasted prevalence in 2050: An analysis for the Global Burden of Disease Study 2019. *The Lancet Public Health*, 7(2), e105–e125. [https://doi.org/10.1016/S2468-2667\(21\)00249-8](https://doi.org/10.1016/S2468-2667(21)00249-8)

Organização Mundial da Saúde. (2023). Obtido 2 de junho de 2024, de <https://www.who.int/news-room/fact-sheets/detail/dementia>

Oh, E. S., & Rabins, P. V. (2019). Dementia. *Annals of Internal Medicine*, 171(5), ITC33–ITC48. <https://doi.org/10.7326/AITC201909030>

Park, D. C., & Bischof, G. N. (2011). Chapter 7—Neuroplasticity, Aging, and Cognitive Function. Em K. W. Schaie & S. L. Willis (Eds.), *Handbook of the Psychology of Aging (Seventh Edition)* (pp. 109–119). Academic Press. <https://doi.org/10.1016/B978-0-12-380882-0.00007-3>

Park, J., Lee, H. J., Park, J. S., Kim, C. H., Jung, W. J., Won, S., Bae, J. B., Han, J. W., & Kim, K. W. (2023). Development of a Gait Feature-Based Model for Classifying Cognitive Disorders Using a Single Wearable Inertial Sensor. *Neurology*, 101(1), e12–e19. <https://doi.org/10.1212/WNL.0000000000207372>

Parque, J., Lee, H. J., Parque, J. S., Kim, C. H., Jung, W. J., Ganhou, S., Bae, J. B., Han, J. G., & Kim, K. W. (2023). Development of a Gait Feature-Based Model for Classifying Cognitive Disorders Using a Single Wearable Inertial Sensor. *Neurology*, 101(1), e12–e19. <https://doi.org/10.1212/WNL.0000000000207372>

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12(85), 2825–2830.

Perry, J. (1992). *Gait Analysis: Normal and Pathological Function*. SLACK.

Peyré-Tartaruga, L. A., & Coertjens, M. (2018). Locomotion as a Powerful Model to Study Integrative Physiology: Efficiency, Economy, and Power Relationship. *Frontiers in Physiology*, 9. <https://doi.org/10.3389/fphys.2018.01789>

Phinyomark, A., Petri, G., Ibáñez-Marcelo, E., Osis, S. T., & Ferber, R. (2018). Analysis of Big Data in Gait Biomechanics: Current Trends and Future Directions. *Journal of Medical and Biological Engineering*, 38(2), 244–260. <https://doi.org/10.1007/s40846-017-0297-2>

Roberts, T. J., Kram, R., Weyand, P. G., & Taylor, C. R. (1998). Energetics of Bipedal Running: I. Metabolic Cost of Generating Force. *Journal of Experimental Biology*, 201(19), 2745–2751. <https://doi.org/10.1242/jeb.201.19.2745>

Santana, I., Farinha, F., Freitas, S., Rodrigues, V., & Carvalho, Á. (2015). Epidemiologia da Demência e da Doença de Alzheimer em Portugal: Estimativas da Prevalência e dos Encargos Financeiros com a Medicação. *Acta Médica Portuguesa*, 28(2), 182–188. <https://doi.org/10.20344/amp.6025>

Santos, C. de S. dos, Bessa, T. A. de, & Xavier, A. J. (2020). Fatores associados à demência em idosos. *Ciência & Saúde Coletiva*, 25, 603–611. <https://doi.org/10.1590/1413-81232020252.02042018>

Schippinger, W. M., & Pichler, G. (2023). Prävention demenzieller Erkrankungen. *Zeitschrift für Gerontologie und Geriatrie*, 56(3), 227–234. <https://doi.org/10.1007/s00391-023-02175-2>

Semba, R. D., Tian, Q., Carlson, M. C., Xue, Q.-L., & Ferrucci, L. (2020). Motoric cognitive risk syndrome: Integration of two early harbingers of dementia in older adults. *Ageing Research Reviews*, 58, 101022. <https://doi.org/10.1016/j.arr.2020.101022>

Silva, F., Ferreira, J. V., Plácido, J., Chagas, D., Praxedes, J., Guimarães, C., Batista, L. A., Laks, J., & Deslandes, A. C. (2020). Gait analysis with videogrammetry can differentiate healthy elderly, mild cognitive impairment, and Alzheimer's disease: A cross-sectional study. *Experimental Gerontology*, 131, 110816. <https://doi.org/10.1016/j.exger.2019.110816>

Singh, D., & Singh, B. (2020). Investigating the impact of data normalization on classification performance. *Applied Soft Computing*, 97, 105524. <https://doi.org/10.1016/j.asoc.2019.105524>

Song, Y., & Lu, Y. (2015). Decision tree methods: Applications for classification and prediction. *Shanghai Archives of Psychiatry*, 27(2), 130–135. <https://doi.org/10.11919/j.issn.1002-0829.215044>

Sousa, A. (2010). *A marcha humana: Uma abordagem biomecânica*.

Starbuck, C. (2023). Logistic Regression. Em C. Starbuck (Ed.), *The Fundamentals of People Analytics: With Applications in R* (pp. 223–238). Springer International Publishing. https://doi.org/10.1007/978-3-031-28674-2_12

Sullivan, G. M., & Feinn, R. (2012). Using Effect Size—Or Why the P Value Is Not Enough. *Journal of Graduate Medical Education*, 4(3), 279. <https://doi.org/10.4300/JGME-D-12-00156.1>

Sutkowy, P., Woźniak, A., Mila-Kierzenkowska, C., Szewczyk-Golec, K., Wesołowski, R., Pawłowska, M., & Nuszkiewicz, J. (2022). Physical Activity vs. Redox Balance in the Brain: Brain Health, Aging and Diseases. *Antioxidants*, 11(1), Artigo 1. <https://doi.org/10.3390/antiox11010095>

Tarwidi, D., Pudjaprasetya, S. R., Adytia, D., & Apri, M. (2023). An optimized XGBoost-based machine learning method for predicting wave run-up on a sloping beach. *MethodsX*, 10, 102119. <https://doi.org/10.1016/j.mex.2023.102119>

Teri, L., Logsdon, R. G., & McCurry, S. M. (2008). Exercise Interventions for Dementia and Cognitive Impairment: The Seattle Protocols. *The journal of nutrition, health & aging*, 12(6), 391–394.

Thys, H., Willems, P. A., & Saels, P. (1996). Energy cost, mechanical work and muscular efficiency in swing-through gait with elbow crutches. *Journal of Biomechanics*, 29(11), 1473–1482. [https://doi.org/10.1016/0021-9290\(96\)84543-X](https://doi.org/10.1016/0021-9290(96)84543-X)

Toot, S., Swinson, T., Devine, M., Challis, D., & Orrell, M. (2017). Causes of nursing home placement for older people with dementia: A systematic review and meta-analysis. *International Psychogeriatrics*, 29(2), 195–208. <https://doi.org/10.1017/S1041610216001654>

Toots, A. T. M., Taylor, M. E., Lord, S. R., & Close, J. C. T. (2019). Associations Between Gait Speed and Cognitive Domains in Older People with Cognitive Impairment. *Journal of Alzheimer's Disease: JAD*, 71(s1), S15–S21. <https://doi.org/10.3233/JAD-181173>

Umberger, B. R., & Martin, P. E. (2007). Mechanical power and efficiency of level walking with different stride rates. *Journal of Experimental Biology*, 210(18), 3255–3265. <https://doi.org/10.1242/jeb.000950>

Unpingco, J. (2016). *Python for Probability, Statistics, and Machine Learning*. <https://doi.org/10.1007/978-3-319-30717-6>

Vergheese, J., Annweiler, C., Ayers, E., Barzilai, N., Beauchet, O., Bennett, D. A., Bridenbaugh, S. A., Buchman, A. S., Callisaya, M. L., Camicioli, R., Capistrant, B., Chatterji, S., De Cock, A.-M., Ferrucci, L., Giladi, N., Guralnik, J. M., Hausdorff, J. M., Holtzer, R., Kim, K. W., ... Wang, C. (2014). Motoric cognitive risk syndrome. *Neurology*, 83(8), 718–726. <https://doi.org/10.1212/WNL.0000000000000717>

Vergheese, J., Lipton, R. B., Hall, C. B., Kuslansky, G., Katz, M. J., & Buschke, H. (2002). Abnormality of gait as a predictor of non-Alzheimer's dementia. *The New England Journal of Medicine*, 347(22), 1761–1768. <https://doi.org/10.1056/NEJMoa020441>

Vergheese, J., Wang, C., Lipton, R. B., & Holtzer, R. (2013). Motoric Cognitive Risk Syndrome and the Risk of Dementia. *The Journals of Gerontology Series A: Biological Sciences and Medical Sciences*, 68(4), 412–418. <https://doi.org/10.1093/gerona/gls191>

Wang, R. (2012). AdaBoost for Feature Selection, Classification and Its Relation with SVM, A Review. *Physics Procedia*, 25, 800–807. <https://doi.org/10.1016/j.phpro.2012.03.160>

Welcome to Python.org. (2024, junho 14). Python.Org. <https://www.python.org/>

Whittle, M. W. (2014). *Gait Analysis: An Introduction*. Butterworth-Heinemann.

Wong, T.-T. (2015). Performance evaluation of classification algorithms by *k*-fold and leave-one-out cross validation. *Pattern Recognition*, 48(9), 2839–2846.

<https://doi.org/10.1016/j.patcog.2015.03.009>

Wu, T., Wei, Y., Wu, J., Yi, B., & Li, H. (2023). Logistic regression technique is comparable to complex machine learning algorithms in predicting cognitive impairment related to post intensive care syndrome. *Scientific Reports*, 13(1), 2485. <https://doi.org/10.1038/s41598-023-28421-6>

Wu, Y.-T., Beiser, A. S., Breteler, M. M. B., Fratiglioni, L., Helmer, C., Hendrie, H. C., Honda, H., Ikram, M. A., Langa, K. M., Lobo, A., Matthews, F. E., Ohara, T., Pérès, K., Qiu, C., Seshadri, S., Sjölund, B.-M., Skoog, I., & Brayne, C. (2017). The changing prevalence and incidence of dementia over time—Current evidence. *Nature Reviews. Neurology*, 13(6), 327–339. <https://doi.org/10.1038/nrneurol.2017.63>

Xu, W., Ferrari, C., Wang, H.-X., Xu, W., Ferrari, C., & Wang, H.-X. (2013). Epidemiology of Alzheimer's Disease. Em *Understanding Alzheimer's Disease*. IntechOpen. <https://doi.org/10.5772/54398>

Zhang, H., & Su, J. (2008). Naive Bayes for optimal ranking. *Journal of Experimental & Theoretical Artificial Intelligence*, 20(2), 79–93. <https://doi.org/10.1080/09528130701476391>

Zhang, Z. (2016). Introduction to machine learning: K-nearest neighbors. *Annals of Translational Medicine*, 4(11), Artigo 11. <https://doi.org/10.21037/atm.2016.03.37>

Zucolotto, T. E., Gerônimo, R. M. P., Silva, P. I. J., & Costa, L. C. S. da. (2023). A inteligência artificial na medicina: Aplicações atuais e potenciais. *Brazilian Journal of Health Review*, 6(6), 31237–31247. <https://doi.org/10.34119/bjhrv6n6-358>

8. APÊNDICES

Apêndice A: Declaração pelo Comitê de Ética do Instituto politécnico de Bragança (IPB)



Declaração

Emitimos parecer favorável ao desenvolvimento do projeto submetido à comissão de Ética do Instituto Politécnico de Bragança, com o número de processo 501020, intitulado “Efeitos do treino multicomponente no risco de doença de alzheimer, aptidão funcional e bem-estar de idosas fisicamente ativas”, o qual tem como objetivos:

avaliar o efeito de um programa de treino multicomponente na: função cognitiva; marcadores da doença de alzheimer; perfil inflamatório; perfil oxidativo; síndrome metabólica; sistema imune; aptidão funcional; tensão arterial; composição corporal; qualidade do sono; índices de solidão; qualidade de vida, e cujo responsável pela investigação é Samuel Gonçalves Almeida da Encarnação orientado pelo Professor Doutor António Miguel de Barros Monteiro

Bragança, 25 de outubro de 2023

A Presidente da Comissão de Ética do
Instituto Politécnico de Bragança

Ana Maria Nunes Galvão
Ana Maria Nunes Português Galvão

Apêndice B: Mini Exame do Estado Mental, versão portuguesa de Guerreiro et al. (1994)

MINIMENTAL STATE EXAMINATION (Folstein, Folstein & McHugh, 1975, com adaptação de Guerreiro e colaboradores, 1994)

I. ORIENTAÇÃO

Vou fazer-lhe algumas perguntas. A maior parte delas são fáceis. Tente responder o melhor que for capaz.” (Dar 1 ponto por cada resposta correta)

1. Em que ano estamos? _____
2. Em que mês estamos? _____
3. Em que dia do mês estamos? _____
4. Em que estação do ano estamos? _____
5. Em que dia da semana estamos? _____
6. Em que País estamos? _____
7. Em que Distrito vive? _____
8. Em que Terra vive? _____
9. Em que casa estamos? _____
10. Em que andar estamos? _____

Nota: _____

II. RETENÇÃO

“Vou dizer-lhe três palavras. Queria que as repetisse e que procurasse decorá-las porque dentro de alguns minutos vou pedir-lhe que me diga essas três palavras.” As palavras são:

PERA

GATO

BOLA

“Repita as três palavras”. (Dar 1 ponto por cada palavra correta)

PERA _____ GATO _____ BOLA _____

Nota: _____

II. ATENÇÃO E CÁLCULO

“Agora peço-lhe que me diga quantos são 30 menos 3 e que ao número encontrado volte a subtrair 3 até eu lhe dizer para parar.”

(Dar 1 ponto por cada resposta correta. Parar ao fim de 5 respostas. Se fizer um erro de subtração, mas continuando a subtrair corretamente partir do erro, conta-se como um único erro)

(30) (27) (24) (21) (18) (15)

Nota: _____

IV. EVOCAÇÃO

(Só se efetua no caso do sujeito ter aprendido as três palavras referidas na prova de retenção) “Agora veja se me consegue dizer quais foram as três palavras que lhe pedi há pouco para repetir.” (Dar 1 ponto por cada resposta correta)

PERA _____

GATO _____

BOLA _____

Nota: _____

V. LINGUAGEM

(Dar 1 ponto por cada resposta correta)

a) Mostrar o relógio de pulso.

“Como se chama isto?” Nota: _____

b) Mostrar um lápis.

“Como se chama isto?” Nota: _____

c) Repetir a frase:

“O rato rói a rolha” Nota: _____

d) “Vou dar-lhe uma folha de papel. Quando eu lhe entregar o papel, pegue nele com a sua mão direita, dobre-o ao meio e coloque-o no chão”.

(Dar 1 ponto por cada etapa bem executada. A pontuação máxima é de 3 pontos.)

Pega no papel com a mão direita _____

Dobra o papel ao meio _____

Coloca o papel no chão _____

Nota: _____

e) “Leia e cumpra o que diz neste cartão.”

Mostrar o cartão com a frase: “FECHE OS OLHOS”. (Dar 1 ponto por cada realização correta).

Nota: _____


f) “Escreva uma frase.”

(A frase deve ter sujeito, verbo e ter sentido para ser pontuada com 1 ponto. Erros gramaticais ou com erros de trocas de letras não contam como erros.)

Nota: _____

g) “Copie o desenho que lhe vou mostrar.” Mostrar o desenho num cartão.

(os 10 ângulos devem estar presentes e 2 deles devem estar intersectados para pontuar 1 ponto. Tremor e erros de rotação não são valorizados)



Nota: _____

NOTA TOTAL: _____

CLASSIFICAÇÃO	
Pontuação	Estado cognitivo
24 a 30 pontos	Normal ou cognitivamente intacta
18 a 23 pontos	Possível comprometimento cognitivo leve
0 a 17 pontos	Comprometimento cognitivo moderado a grave